

---

Impacte de informação promocional na previsão de procura intermitente no setor do retalho

**Marta Filipa Martins Ramos**

---

Dissertação  
Mestrado em Economia

---

Orientado por  
**Professor Doutor José Manuel Soares Oliveira**  
**Professora Doutora Patrícia Alexandra Gregório Ramos**

---

2018



## **Nota Biográfica**

Marta Filipa Martins Ramos, natural de Espinho, nasceu no dia 21 de Janeiro de 1994.

Em 2013, iniciou os estudos na Faculdade de Economia do Porto, na licenciatura em Gestão. Após a sua conclusão, em 2016, ingressou no mestrado em Economia na mesma instituição.

## **Agradecimentos**

Quero agradecer, antes de mais e particularmente aos meus orientadores, Professor Doutor José Manuel Soares Oliveira e Professora Doutora Patrícia Alexandra Gregório Ramos pela dedicação e empenho ao longo de toda a elaboração da dissertação, pela incessante partilha de conhecimento e pelo rigoroso acompanhamento teórico, metodológico e prático.

À minha família e a todos os meus amigos mais próximos, pelo incentivo e paciência ao longo deste percurso.

## Resumo

Este trabalho pretende prever a procura intermitente de produtos do setor do retalho num contexto promocional. A importância da previsão deste tipo de vendas tem aumentado no setor pois, a intermitência associada a séries temporais, com valores nulos, representa um obstáculo às previsões e, para além disso, os retalhistas têm intensificado as suas campanhas promocionais com reduções de preço constantes, que complexificam significativamente o problema.

Para alcançar o objetivo, utiliza-se um conjunto de dados relativos às vendas de lojas Pingo Doce do Grupo Jerónimo Martins, no período de Janeiro de 2012 a Abril de 2015, e aplica-se uma metodologia de avaliação de eficiência de previsão. Com recurso ao *software* R são aplicados vários modelos de previsão para dados de natureza intermitente, tanto com inclusão de variáveis exógenas como sem o envolvimento das mesmas. Com isto, identificam-se as práticas de previsão mais precisas e adequadas a utilizar no setor do retalho e também a eficiência e eficácia das campanhas promocionais existentes.

Utilizando medidas de erro para avaliar o desempenho das várias abordagens, de um modo geral o modelo que apresenta melhor performance é o modelo de espaço de estados com probabilidade de ocorrência baseado no TSB, com a inclusão de variáveis exógenas - as promoções, podendo o ganho relativamente ao *benchmark* ser de 27%.

Os resultados obtidos mostram que a introdução de informação promocional melhora a previsão, ou seja, a introdução de variáveis exógenas permite uma melhor compreensão do dia a dia dos retalhistas e como este é afetado pelas promoções, obtendo-se assim previsões de vendas mais próximas da realidade.

**Palavras-chave:** Previsão de vendas, Procura intermitente, Modelos de espaço de estados, Promoções, Retalho, Gestão de *stocks*.

**Códigos JEL:** C32, C53, L81, M30

## Abstract

This work is intended to forecast sales of intermittent retail products in the promotional context. The importance of this type of sales has been higher, so an intermittency associated with a time series with null values is an obstacle to forecasts and, in addition, retailers had been intensifying their promotional campaigns with constant price reductions, which complicate a lot the problem.

In order to achieve the objective of this dissertation, a set of sales data from Pingo Doce stores, Jerónimo Martins Group, from January 3, 2012 to April 27, 2015 was used, and a methodology for evaluating forecast efficiency was applied. Using the software R, several forecast models for intermittent data were applied, both with and without the inclusion of exogenous variables. This enabled us to identify the most accurate and appropriate forecasting practices to use in the retail sector, as well as the efficiency and effectiveness of promotional campaigns.

Considering the error measures used to measure the performance of the models, in general, the model that gives the best results is the state space model with probability based on TSB, with exogenous variables - the promotions. The improvement relatively to the benchmark can be up to 27%.

The results show that the introduction of promotional information improves the forecast, which means that the introduction of exogenous variables allows a better understanding about the daily day activities of the retailers and how the promotions impacts them. Thus, the results show that the sales forecasts are closer to the reality.

**Keywords:** Sales forecast, Intermittent demand, State-space models, Promotions, Retail, Stock management

**JEL Codes:** C32, C53, L81, M30

## Índice

Nota Biográfica.....	i
Agradecimentos .....	ii
Resumo .....	iii
Abstract.....	iv
Índice.....	v
Índice de Tabelas .....	vi
Índice de Figuras .....	vii
Índice de Gráficos .....	viii
Índice de Anexos.....	ix
Lista de Abreviaturas.....	x
1. Introdução .....	1
2. Revisão de Literatura .....	4
2.1. Promoções .....	4
2.2. Gestão de <i>Stocks</i> .....	8
2.3. Previsão de Vendas .....	10
3. Metodologia.....	18
3.1 Métodos de Previsão para Séries Intermitentes .....	18
3.2 Modelos de Espaço de Estados para Séries Intermitentes .....	20
3.3 Multiple Aggregation Prediction Algorithm .....	26
4. Caso de Estudo.....	28
4.1. Grupo Jerónimo Martins .....	28
4.2. Conjunto de Dados.....	30
4.3. Avaliação do Desempenho da Previsão .....	34
4.4. Resultados.....	39
5. Conclusões.....	43
6. Referências Bibliográficas.....	45
7. Anexos .....	51

## Índice de Tabelas

Tabela 1. Número de SKUs por área e respectiva percentagem .....	32
Tabela 2. Cálculo do valor do PIS.....	37
Tabela 3. Ganho dos métodos em relação ao Naïve. Entre parêntesis, ganho dos modelos com X relativamente aos modelos equivalentes sem X.....	42



## Índice de Figuras

Figura 1. Conjunto de treino e conjunto de teste .....	33
Figura 2. Processo de <i>rolling</i> .....	38

## Índice de Gráficos

Gráfico 1. Número de promoções no setor do retalho em Portugal .....	5
Gráfico 2. Vendas ao abrigo de promoções .....	6
Gráfico 3. Impacte do <i>stock-out</i> no comportamento dos consumidores .....	9
Gráfico 4. Vendas Jerónimo Martins por área de negócio 2017 .....	29
Gráfico 5. Vendas Pingo Doce de 2012 a 2017 .....	30

## Índice de Anexos

Anexo 1. Impacto nos níveis de inventário com a melhoria da previsão versus programação da produção e otimização de stock de segurança .....	51
Anexo 2. Fases do método MAPA .....	52
Anexo 3. Fluxograma do processo do cálculo para cada nível de agregação temporal do MAPA com variáveis exógenas .....	52
Anexo 4. Séries de vendas, preços e promoções de seis SKUs .....	54
Anexo 5. Resultados de erros de previsão sMAE, sMSE, MASE e sMAPIS .....	55
Anexo 6. <i>Rank</i> do desempenho dos modelos obtido com sMAE, sMSE, MASE e sMAPIS .....	56
Anexo 7. Teste estatístico Nemenyi para os quatro instantes com sAE.....	57
Anexo 8. Teste estatístico Nemenyi para os quatro instantes com sSE .....	58
Anexo 9. Teste estatístico Nemenyi para os quatro instantes com ASE.....	59
Anexo 10. Teste estatístico Nemenyi para os quatro instantes com sAPIS .....	60

## **Lista de Abreviaturas**

AIC - Akaike Information Criterion  
APED - Associação Portuguesa de Empresas de Distribuição  
ARIMA - Autoregressive Integrated Moving Average  
EBITDA - Earnings Before Interest, Taxes, Depreciation and Amortization  
ECR Europe – Efficient Consumer Response Europe  
EDLP - Every Day Low Pricing  
ETS – Erro, Tendência, Sazonalidade  
HILO - High Low Pricing  
iETS – Erro, Tendência e Sazonalidade Intermitente  
iMAPA – Intermittent Multiple Aggregation Prediction Algorithm  
MAPA - Multiple Aggregation Prediction Algorithm  
MARMA - Multivariate Autoregressive Moving Average  
MASE - Mean Absolute Scaled Error  
PIS – Períodos em Stock  
PVP – Preço de Venda ao Público  
SBA - Aproximação de Syntetos-Boylan  
SES – Alisamento Exponencial Simples  
SKU – Stock Keeping Unit  
sAE – Scaled Absolute Error  
sAPIS – Scaled Absolute Periods in Stock  
sMAE - Scaled Mean Absolute Error  
sMAPIS - Scaled Mean Absolute Periods in Stock  
sMSE - Scaled Mean Squared Error  
sPIS – Scaled Periods in Stock  
sSE – Scaled Squared Error  
TSB - Teunter, Syntetos e Babai

## 1. Introdução

A previsão de vendas constitui o primeiro passo para o planeamento da atividade das empresas de retalho. A determinação de previsões e a análise prévia dos seus resultados são imprescindíveis para atingir objetivos reais e efetivos (Caiado, 2016). Neste contexto, e devido ao quotidiano que vivemos nos dias de hoje, os retalhistas têm de efetuar previsões de vendas de milhões de produtos de diferentes categorias e especificações, sendo cada vez mais importante a obtenção de previsões próximas do valor real da procura registada. Esta precisão nas previsões permite aos retalhistas efetuar alterações de produção e/ou logística, se assim necessário, de forma a resolver problemas que por vezes impossibilitam o seu sucesso e a satisfação dos clientes.

Uma má previsão de vendas representa para o retalhista perdas, tanto por excesso como por rutura de *stock*. Isto porque, em caso de excesso de *stock* o retalhista fica com produto em armazém e isso acarreta custos tanto de armazenamento como de deterioração do produto. Já em caso de rutura de *stock*, o retalhista vende menos unidades do que aquelas que os consumidores estariam dispostos a comprar. Com base num estudo que abrangeu 11 países, 115 categorias de produtos, mais de 20 mil respostas de consumidores e mais de 1 milhão de dados, foram estudadas as preferências e necessidades dos consumidores (ECR Europe, 2003). Segundo este estudo as ruturas de *stock* são consideradas o terceiro maior problema para os consumidores, sendo que 21% destes recorrem a outro retalhista para obter o produto (ao contrário do que se pensava), 37% mudam de marca, 17% voltam mais tarde à loja e 16% adquirem diferentes tamanhos do produto (continuando apesar de tudo a comprar) e finalmente 9% não efetuam qualquer compra (ECR Europe, 2003).

Atualmente, as promoções e campanhas promocionais estão cada vez mais presentes nas superfícies comerciais de retalho, sendo que no mesmo estudo estas ocupam o segundo lugar das preferências dos consumidores (ECR Europe, 2003). Devido à elevada concorrência, os retalhistas têm intensificado as suas campanhas promocionais com reduções de preço constantes, provocando um aumento das vendas de produtos nos períodos em que estes se encontram em promoção. Uma evidência desta situação são os dados da APED (Dinheiro Vivo, 2017) e da Revista Consumo (Rodrigues, 2015) que mostram que as promoções sofreram um aumento de 19,8% entre 2012 a 2016. No entanto, as campanhas promocionais constantes por parte dos diferentes retalhistas complexificam o problema de obtenção de previsões de vendas precisas.

Nesta dissertação será estudada a previsão de vendas de produtos que apresentam períodos de procura nula, habitualmente designados por *slow moving goods*, sobre os quais incidem também campanhas promocionais. Esse estudo utilizará dados reais de vendas da empresa de retalho Pingo Doce, pertencente ao Grupo Jerónimo Martins. Recentemente, devido às modificações do mercado esta empresa sentiu necessidade de alterar a sua estratégia de *Every Day Low Pricing* (EDLP), caracterizada pela existência de preços baixos e inexistência de promoções, para uma estratégia de *High Low Pricing* (HILO), com práticas promocionais frequentes.

A intermitência associada a séries temporais com valores nulos apresenta-se como um problema no processo de previsão, sendo por essa razão, uma área de investigação ainda pouco desenvolvida e com técnicas muito recentes. Contudo, e concretamente no setor do retalho, cerca de 60% do volume total de bens comercializados tem uma procura de base intermitente, o que mostra bem a relevância do tema (Petropoulos e Kourentzes, 2015). Para além disso, e como mencionado anteriormente, os retalhistas têm intensificado as suas campanhas promocionais o que complexifica ainda mais o processo de previsão.

Dado que a gestão e controlo de *stocks* tem por base uma previsão da procura, uma previsão de vendas de bens intermitentes precisa está diretamente relacionada com níveis ótimos de *stock* (Petropoulos *et al.*, 2016). Sendo assim, e tratando-se de um tema pouco estudado, numa área científica em desenvolvimento, há uma elevada motivação para evoluir e progredir, com consequências de extrema importância para o mercado de retalho.

O objetivo desta dissertação consiste na previsão da procura de *slow moving goods* do setor de retalho sob efeito de ações promocionais. É necessário adequar o método de previsão aos dados disponíveis, incorporando as promoções, de forma a tornar as previsões mais precisas, para que, de um ponto de vista prático, o retalhista decida com menor incerteza quais os produtos a promover e pratique uma gestão de *stocks* eficiente.

Esta dissertação está dividida em cinco capítulos, sendo o primeiro a presente introdução. O segundo diz respeito à revisão de literatura, onde se apresentam os conceitos-chave associados ao tema em estudo, realizando-se um enquadramento teórico do problema e uma análise crítica dos diferentes contributos. No terceiro capítulo é definida a metodologia a utilizar para resolver a questão de investigação e no quarto é apresentado o caso de estudo, com o enquadramento do Grupo Jerónimo Martins, seguindo-se a descrição e tratamento do conjunto de dados disponível, a explicação das medidas de avaliação de desempenho utilizadas e por fim os resultados obtidos neste estudo. No último e quinto capítulo são

indicadas as conclusões e as limitações desta investigação, referindo orientações para possíveis investigações futuras, seguindo-se as referências bibliográficas.

## 2. Revisão de Literatura

Neste capítulo será realizada a revisão de literatura, apresentando-se os conceitos-chave associados ao tema em estudo, concretamente as promoções, a gestão de *stocks* e a previsão de vendas e de procura intermitente, realizando-se um enquadramento teórico do problema e uma análise crítica dos diferentes contributos na literatura.

Inicialmente será explicitado a importância das promoções e a sua evolução ao longo dos anos, como podem afetar o comportamento dos consumidores e as vendas dos retalhistas. Seguidamente, será explicitado como as previsões e promoções afetam tanto a gestão de *stocks* dos retalhistas como o comportamento dos consumidores e como todos estes conceitos-chave estão interligados, estando dependentes uns dos outros para que o sucesso do setor seja alcançado. Por fim, serão apresentados diferentes métodos de previsão de vendas e os seus contributos para o tema de investigação.


### 2.1. Promoções

As ações promocionais surgiram no início dos anos 70 do século passado, continuando a crescer até aos dias de hoje, tornando-se para a maioria das empresas a parte mais significativa do orçamento do departamento de *marketing* (Srinivasan *et al.*, 2004), isto porque, segundo Cooper *et al.* (1999) o planeamento das promoções é uma tarefa diária tanto para os retalhistas como para os produtores. Chaharsoughi e Yasory (2012) vão de encontro com Blattberg e Neslin (1990) definindo promoções como eventos de *marketing* que têm como objetivo afetar diretamente o comportamento dos consumidores. De uma forma mais genérica, Shimp e Andrews (2013) afirmam que as promoções são um incentivo criado pelos produtores e fornecedores para estimularem os consumidores a adquirirem uma determinada marca, produto ou serviço no período de tempo em que o preço é alterado, influenciando diretamente a escolha da marca, o período da compra e a quantidade adquirida. As promoções têm a capacidade de se transformarem numa justificação suplementar e plausível para o consumo, fomentando as compras por impulso, a aquisição de novos produtos/serviços, e o escoamento do *stock* (Honea e Dahl, 2005). Essencialmente, têm como principal objetivo atrair clientes às lojas, aumentar a sua assiduidade e aumentar as vendas (Srinivasan *et al.*, 2002). As promoções estão associadas a ofertas gratuitas, promoção de preços e quantidade, ofertas *premium*, cartões de fidelização, *merchandising*, entre outros (Kotler e Keller, 2012; Pickton e Broderick, 2005). Destes, a promoção de preços através da sua redução direta é o mais utilizado no setor do retalho, no entanto, Mishra e Mishra (2011)



mostram que as promoções de quantidade têm vindo a aumentar, sendo cada vez mais as eleitas pelos consumidores, dependendo do produto em questão.


O setor do retalho é uma indústria muito competitiva apresentando na última década campanhas promocionais constantes. Uma análise efetuada pela Marktest (2014) mostra que foi a partir do ano de 2012 que as ações promocionais sofreram grandes modificações, afirmando que foi nesse mesmo ano que a era promocional se iniciou em Portugal. Esta fonte supõe que a empresa Pingo Doce foi a principal impulsionadora, pois no dia 1 de Maio de 2012 lançou uma mega campanha promocional de redução de preços.



Fonte: Marktest (2014)

Gráfico 1. Número de promoções no setor do retalho em Portugal

Observando o Gráfico 1, podemos concluir que, no setor do retalho, foi em 2013 que se registou o maior número de promoções (mais do dobro do ano anterior), sendo, no entanto, importante referir que as promoções iniciaram o seu crescimento a partir de 2012 (o que demonstra a intensa relação entre a campanha do dia 1 de Maio de 2012 e o início da era promocional em Portugal). Segundo dados da Revista Consumo (Rodrigues, 2015) e da APED (DinheiroVivo, 2017 e DinheiroVivo, 2018c), de 2012 a 2017, o crescimento das vendas com recurso a promoções tem registado um aumento acentuado, tal como podemos visualizar no Gráfico 2.



Fonte: Rodrigues (2015), (DinheiroVivo, 2017), (DinheiroVivo, 2018c)

Gráfico 2. Vendas ao abrigo de promoções

No entanto, no ano de 2017, segundo os dados da APED, as promoções representaram 45% das vendas no setor do retalho em Portugal, uma subida de apenas 0,2 pontos percentuais em relação a 2016, demonstrando que neste último ano, o aumento das vendas com promoção foi menor, o que faz acreditar que a era promocional entrou num período estacionário, com um aumento pouco substancial em relação aos anos anteriores. O aumento acentuado dos anos anteriores deveu-se às constantes alterações dos mercados, ao comportamento dos consumidores, à abundância de produtos, serviços e informação disponível (que para além de tornarem o mercado muito competitivo levam por vezes à necessidade de escoamento de *stocks*), às pressões por parte dos fornecedores e ainda à forte crise económico-financeira de 2008, que provocou períodos de recessão, onde o poder de compra dos consumidores era inferior e a sensibilidade aos preços superior, tornando assim as ações promocionais mais valorizadas (Huang *et al.*, 2014). Esta última situação confirma a ideia de estabilização atual da era promocional referida anteriormente, pois uma das razões para essa estabilização poderá ser o fim da crise económico-financeira.

Os retalhistas despendem uma grande proporção do seu orçamento em reduções de preços e promoções (Huang *et al.*, 2014), pois estas são um elemento importante na dinâmica competitiva nos mercados de retalho e no desempenho e sucesso do retalhista. Segundo Ma e Fildes (2017), devido ao uso generalizada das promoções no setor de retalho e ao elevado investimento monetário neste processo, o planeamento das promoções deve ser analisado ao pormenor, pois tem a capacidade de fazer uma grande diferença nos lucros dos retalhistas,

permitindo aos gestores definir a melhor estratégia para a empresa, com campanhas promocionais bem delineadas e informadas e com a capacidade de prever as ações e respostas dos concorrentes. Neste mercado com elevada concorrência de preços, pequenos melhoramentos nas decisões operacionais podem alterar todo o equilíbrio competitivo da empresa, permitindo que esta perdure e evolua (Bolton *et al.*, 2010; Chapados *et al.*, 2014).

Segundo Gardener e Trivedi (1998), as promoções afetam os consumidores de diferentes formas. A satisfação dos consumidores em relação a uma marca promovida leva ao aumento do número de compras futuras repetidas mesmo após a conclusão da promoção (Rothschild e Gaidis, 1981). No entanto, esta opinião é contrariada por alguns autores que afirmam que, nestas condições, o comportamento dos consumidores volta àquele que tinham anteriormente, numa situação sem promoção (Bawa e Shoemaker, 1987), sendo esta opinião corroborada por outros, que defendem que, quando uma promoção é retirada, a probabilidade de os consumidores voltarem a comprar diminui (Guadagni e Little, 1983). Contudo, é consensual na literatura que promoções com redução de preço provocam um aumento das vendas num curto período de tempo, ou seja, as intenções de compra aumentam no período promocional (Bawa e Shoemaker, 1987, Bell *et al.*, 1999). Apesar das campanhas promocionais provocarem um aumento das vendas dos produtos em promoção, isso não significa que esse aumento de vendas seja vantajoso para o retalhista. Isto porque o aumento das vendas do produto em promoção pode ser resultado de promoções noutros intervalos de tempo ou sobre outros produtos, ou resultado de um comportamento definido como *stockpiling*, ou seja, os consumidores compram mais unidades de produtos em promoção e apenas os utilizam mais tarde (Ma e Fildes, 2017). Em média, 10% a 20% das vendas dos produtos promocionais são feitas como compras aceleradas ou de armazenamento, ou seja, é efetuada a compra de mais unidades do que o habitual ou é efetuada uma compra antecipada. O que significa que nestas situações, durante um curto período de tempo subsequente os consumidores não valorizam as promoções de artigos substitutos (Bell *et al.*, 1999). Outra das razões que explica o porquê de os retalhistas não beneficiarem das promoções é a troca de marca na presença de redução de preços, sendo este o principal efeito das ações promocionais (Gupta, 1988; Ma e Fildes, 2017). Estudos mostram que, em média, cerca de um terço do aumento das vendas durante ações promocionais é imputado a perdas incorridas por outras marcas (Heerde *et al.*, 2003). Para que os retalhistas consigam obter lucros e benefícios com as promoções, é essencial que estes consigam estruturar e planear o preço-promoção. Bolton *et al.* (2010) afirmam que o sucesso dos retalhistas depende da

capacidade de equilíbrio entre os preços e as promoções, para os diferentes tipos de clientes, lojas e para os diferentes produtos e categorias dentro da mesma marca.

Para a obtenção de um planeamento eficiente e eficaz da cadeia de abastecimento é necessário a existência de um sistema de previsão preciso que incorpore informação promocional, permitindo assim aos retalhistas e produtores beneficiarem das promoções, atingindo maiores lucros e aumentando a satisfação dos seus clientes.


## **2.2. Gestão de *Stocks***

A gestão de *stocks* é uma forma de planeamento e fiscalização dos produtos necessários e existentes em armazém, garantindo que o aprovisionamento existente permita satisfazer a procura dos clientes. Isto está diretamente dependente das cadeias de distribuição, que se estendem desde o cliente final, aos retalhistas, distribuidores, fabricantes até aos fornecedores, existindo fluxos de materiais, produtos, informações e dinheiro ao longo do processo (Syntetos *et al.*, 2016). Quem define a cadeia de distribuição é a procura dos clientes finais, pois é essa procura que define a quantidade de *stock* necessária.

Os retalhistas podem praticar uma boa ou uma má gestão de *stocks*. Quando a gestão é efetuada de forma eficiente, esta concede ao retalhista uma vantagem competitiva face à concorrência e uma maior segurança na conjuntura financeira da organização. No entanto, na presença de uma má gestão de *stocks*, podemos encontrar duas situações em loja: excesso ou rutura de *stock*. É consensual na literatura que a presença de promoções aumenta a procura no período promocional e, conseqüentemente, provoca mais rapidamente a rutura do *stock* dos bens em promoção. Segundo Corsten e Gruen (2003), em média, as taxas de rutura de *stock* de bens em promoção apresentam valores duas vezes maiores do que as taxas de rutura de *stock* de bens sem promoção. Estudos levados a cabo pela ECR Europe (2003) vão ao encontro da mesma ideia, mostrando que em França a taxa de rutura de *stock* de bens em promoção é 75% superior à taxa de rutura de *stock* de bens sem promoção, e na Holanda a taxa é 35% superior. Sendo assim, no caso de ineficiência na previsão da procura, os elevados níveis de rutura de *stock* de bens em promoção anulam os benefícios previstos da ação promocional (ECR Europe, 2003).

Um estudo realizado por Corsten e Gruen (2004) com mais de 71 000 consumidores mundiais mostra a falta de paciência para ruturas de *stock*, pois isso significa perda de tempo, dinheiro e energia para o consumidor. Quando o produto procurado não existe, 9% dos consumidores tende a não efetuar a compra, ficando os consumidores mais suscetíveis à

troca de retalhista, ou seja, recorrem à concorrência (31%), em vez de trocar de marca (26%) (Gráfico 3).



Fonte: Corsten e Gruen (2004)

Gráfico 3. Impacte do *stock-out* no comportamento dos consumidores

Estes comportamentos praticados pelos consumidores em caso de rutura de *stock* provocam aos retalhistas e produtores inúmeras perdas, com uma estimativa anual de 4 biliões de euros, valor este que na realidade é bastante superior, pois apenas contabiliza as perdas com os consumidores que optam por não comprar, não contabilizando as possíveis perdas provocadas pelo adiamento da compra, troca de loja, marca ou categoria de produto e as perdas incorridas por excesso de *stock*. No caso específico do Pingo Doce, a combinação destes comportamentos com outros fatores, permite quantificar a perda de lucros no valor de 4,3 milhões de euros por ano, o que demonstra a importância de uma boa gestão de *stocks* (ECR Europe, 2003).

O planeamento da cadeia de abastecimento está dependente das previsões de vendas, no qual a sua precisão tem consequências positivas para todos os intervenientes (Fildes *et al.*, 2009). Desenvolvido pela IBM ILOG (2010), o Anexo 1, corrobora a afirmação anterior, isto é, quanto melhor é o planeamento da produção, maior é a otimização do *safety stock* e quanto mais precisas forem as previsões, menor é a variabilidade dos produtos. Então, numa conjuntura ideal, com o melhor planeamento e previsão obtêm-se melhoramentos de 31% nos níveis de *stock*. Apesar da precisão da previsão ser o fator crucial para resolver a má gestão de *stocks*, existem outros comportamentos que podem ser adotados, como a otimização da interligação entre a previsão de vendas, o planeamento do *stock* e o planeamento do reabastecimento, pois é necessário ver estas atividades como um processo e não como ações individuais.

Assim, maior eficiência e precisão permitem ao retalhista diminuir as suas perdas, proporcionar com êxito toda a procura, aumentando a satisfação dos clientes e consequentemente aumentando os seus lucros (Hyndman e Athanasopoulos, 2012).

### 2.3. Previsão de Vendas

Previsão de vendas é uma projeção futura da procura esperada dado um conjunto estabelecido de conjunturas como dados históricos de vendas, movimentos dos mercados, pareceres de especialistas e variáveis exógenas (Mentzer e Moon, 2004; Aras *et al.*, 2017). Esta utiliza tanto métodos qualitativos como quantitativos dependendo do contexto da empresa, de forma a resolver as necessidades dos utilizadores das previsões. Os métodos qualitativos são utilizados em casos de carência ou escassez de dados históricos e têm por base o conhecimento e informação de clientes, gestores e especialistas, enquanto os métodos quantitativos são utilizados na presença de dados históricos relevantes, assumindo uma situação de padronização em períodos futuros.

No setor do retalho a importância da eficácia da previsão de vendas tem vindo a aumentar nos últimos anos, tornando-se um processo cada vez mais complexo devido à inter-relação de fatores como a intermitência das séries, a existência de diferentes escalas, o encurtamento dos ciclos de vida dos produtos, a mudança de tendências, as promoções, os mercados em constantes alterações e cada vez mais competitivos, o ambiente económico e o *marketing* cada vez mais agressivo por parte dos retalhistas (Fildes *et al.*, 2009; Trapero *et al.*, 2013). Neste setor existem dois tipos de bens: *fast moving goods* e *slow moving goods*. Ao contrário dos *fast moving goods*, que apresentam uma frequência regular de vendas, os *slow moving goods* apresentam séries temporais intermitentes, ou seja, séries com valores nulos e não nulos com frequência irregular (Kourentzes, 2013; Svetunkov e Boylan, 2017; Hinton, 1999; Syntetos *et al.*, 2009; Molenaers *et al.*, 2010). Esta dissertação foca-se na previsão de vendas de *slow moving goods*, no entanto será feito um ligeiro enquadramento relativo aos *fast moving goods* para que a temática seja compreendida de forma mais consistente.

A literatura existente para previsões de vendas apresenta metodologias de previsão distintas para cada tipo de bem, diversos níveis de agregação de dados e diferentes medidas para os erros de previsão.

Para *fast moving goods* o primeiro método de previsão foi proposto por Curry *et al.* (1995) utilizando modelos como o *Bayesian* Var, MARMA, *Box-Jenkins* e o alisamento exponencial. Ao longo dos anos surgiram outros modelos, mas a grande evolução nesta

temática foi obtida por Aburto e Weber (2007) com a criação de um modelo de previsão híbrido, o ARIMA (*Autoregressive Integrated Moving Average*) e Redes Neurais, concluindo que a conjugação destes modelos apresenta previsões mais precisas do que o uso individual dos mesmos. Para além destes, outros dos métodos mais utilizados em várias indústrias, ainda nos dias de hoje, são o *naïve* e o alisamento exponencial simples (SES - *Simple Exponential Smoothing*), pois a sua simplicidade torna-se uma vantagem para os utilizadores. Com o objetivo de melhorar a precisão das previsões de vendas, pois pequenas melhorias podem levar a grandes poupanças monetárias, maior competitividade, melhorias nos canais de distribuição e ainda aumento da satisfação dos clientes (Moon *et al.*, 2003), foi proposto por Hyndman *et al.* (2008) modelos estatísticos subjacentes a métodos de alisamento exponencial, denominados de modelos de espaço de estados. Estes modelos para além de produzirem previsões pontuais, obtidas também por outros, conseguem em simultâneo gerar intervalos de previsão. Para cada um dos 15 métodos de alisamento exponencial, existem dois modelos de espaço de estados possíveis, um correspondente a um modelo com erros aditivos e o outro correspondente a um modelo com erros multiplicativos, perfazendo assim 30 potenciais modelos de previsão.

No entanto, para alcançar bons resultados de previsão de vendas é imprescindível ajustar o modelo de previsão à série temporal de dados existente. Um dos aspetos a considerar é o facto de a série ter ou não valores nulos. Apesar dos diferentes métodos e modelos apresentados anteriormente obterem bons resultados para os *fast moving goods*, o mesmo não acontece para *slow moving goods*, levando a que esses métodos não possam ser aplicados na previsão de dados intermitentes. No entanto, apesar desta dificuldade, as séries temporais de dados intermitentes, que apresentam valores nulos e normalmente dados discretos com valores inteiros baixos, têm uma importância acentuada, ocorrendo em diversas áreas, como por exemplo, em falhas de segurança, catástrofes naturais, maquinaria pesada na área militar, peças de aeronaves, de automóveis, de embarcações marítimas, no setor das tecnologias de informação e na procura de bens do tipo *slow moving goods* (Kourentzes, 2013; Svetunkov e Boylan, 2017). Estes exemplos foram corroborados por diversos estudos. Hinton (1999) afirmou que o Departamento de Defesa dos EUA possuiu 60% de excesso de *stock* de peças sobressalentes, dos quais 18% não apresentam nenhuma procura, Syntetos *et al.* (2009) constataram que na Suécia, parte do *stock* de peças sobressalentes não detiveram qualquer movimento no inventário nos últimos 10 anos, Molenaers *et al.* (2010) discutiram um caso de estudo onde 54% das peças armazenadas numa

empresa petroquímica apresentavam procura zero nos últimos 5 anos e foi provado por Johnston *et al.* (2003) que os produtos com procura intermitente podem representar até 60% do valor total de *stock* dos retalhistas. É importante frisar esta percentagem no setor do retalho porque, apesar de os produtos com procura intermitente não serem vendidos todos os dias, correspondem a uma grande quantidade do *stock* e por sua vez a um elevado peso no setor. Devido ao facto de os clientes valorizarem uma grande diversidade de produtos, é necessária a presença destes em loja e a realização de previsões precisas para definir com a menor incerteza possível a quantidade necessária de *stock*.

Assim, sendo a previsão a base do planeamento, boas decisões de planeamento e gestão traduzem-se em melhorias de custos e de competitividade para a empresa. No entanto, a gestão destes produtos não recebeu muita atenção por parte da literatura, tendo vindo apenas a crescer nos últimos anos, devido às implicações que isto traz nas decisões de planeamento. Por isso, a previsão de dados intermitentes e o controlo de *stocks* tem sido um grande problema no setor do retalho, porque por si só a previsão de vendas é uma tarefa complexa, tornando-se ainda mais difícil devido à natureza intermitente dos dados, à variabilidade do tamanho da procura e à variabilidade do padrão de procura (Syntetos e Boylan, 2001). Esta dificuldade cresce ainda mais quando, no caso do setor do retalho, se aplica a ações promocionais. Esta realidade é cada vez mais comum para os retalhistas, e por isso, é necessário criar sistemas de previsão precisos e eficazes, pois a boa gestão de inventários, as decisões de reabastecimento de *stock*, as estratégias futuras da empresa e o planeamento individual para cada produto, que representam o sucesso da empresa, dependem disso.

É então indispensável decidir qual o método de previsão de procura intermitente a usar para os dados disponíveis. De forma a perceber a temática que será discutida nesta dissertação é necessário efetuar um enquadramento teórico da questão de investigação, com foco nos métodos de previsão de procura intermitente, o seu funcionamento e evolução até aos dias de hoje. Existem 3 perspetivas diferentes de métodos aplicados a dados de natureza intermitente, propostos e testados por vários autores. Numa primeira perspetiva:

O alisamento exponencial simples (SES - *Simple Exponential Smoothing*), proposto por Brown (1959) foi o primeiro método de previsão aplicado a dados de natureza intermitente. Este método é aplicado diretamente nos dados originais e a sua previsão corresponde a uma média ponderada da observação mais recente e da previsão mais recente. Este método, apesar de ter surgido há mais de seis décadas, é ainda muito utilizado atualmente em trabalhos de



investigação e na indústria, talvez devido à sua simplicidade e fácil aplicação. No entanto, é unanimemente aceite que apresenta um mau desempenho na previsão de dados intermitentes (Kourentzes, 2013; Svetunkov e Boylan, 2017), pois, existe uma tendência ascendente na previsão num período diretamente após uma procura não nula, exibindo enviesamento na previsão (Croston, 1972). Este acontecimento é bastante importante visto que o cálculo de *stocks* é realizado nesse mesmo ponto, ou seja, após a existência de procura, o que provoca normalmente desnecessários níveis de *stock* elevados, demonstrando assim as desvantagens e limitações deste método (Nikolopoulos *et al.*, 2011; Syntetos *et al.*, 2015).

Na sequência deste trabalho, Croston concluiu que métodos tradicionais, incluindo o SES, não tinham um bom desempenho em séries temporais de procura intermitente. Tendo por base o SES, Croston (1972) criou um novo método de previsão adequado para dados de natureza intermitente, o método de Croston, que foi mais tarde corrigido por Rao (1973). Neste método, a série temporal é dividida em duas componentes: dados de procura não nula e intervalos de tempo entre procura não nula; de seguida estas duas novas séries são previstas de forma independente utilizando SES, aplicando-se o mesmo parâmetro de alisamento  $\alpha$  a ambas (Kourentzes, 2014). Croston (1972) sugere um valor de  $\alpha$  entre 0.1 e 0.3, já Syntetos e Boylan (2001) defendem que o valor de  $\alpha$  não deverá ser superior a 0.15, mas estudos mais recentes realizados pelos mesmos autores mostram que o valor deve situar-se entre 0.05 e 0.2 (Syntetos e Boylan, 2005). Para além disso, em 2011, foram estudados valores de  $\alpha$  superiores a 0.3 e concluiu-se que dependendo dos níveis de intermitência, diferentes valores de  $\alpha$  produzem um enviesamento mínimo, o que demonstra que é necessário ajustar os parâmetros a cada série temporal diferente (Kourentzes, 2014). A previsão final é então determinada pelo quociente das duas previsões e representa a procura média por período (Petroopoulos *et al.*, 2016). Desde a sua criação que este método tem vindo a ser investigado e aplicado em casos reais, provando a existência de alguns problemas. A primeira e grande limitação é o enviesamento do método. Uma outra crítica, elaborada por Willemain *et al.* (1994) e Kourentzes (2013), está relacionada com a forte afirmação de Croston sobre a independência existente entre as duas componentes, conjuntura que se provou contrária e mais benéfica. Shenstone e Hyndman (2005) afirmam que este método é inconsistente com as propriedades dos dados de procura intermitente, porque assume a estacionaridade enquanto qualquer modelo possível subjacente ao método não deve ser estacionário. Além disso, o modelo subjacente deve ser definido num espaço de amostra contínuo que pode assumir valores de procura negativos ou positivos, algo que é inconsistente com a realidade

de que a procura é sempre não-negativa. No entanto, apesar das limitações, este método conseguiu obter alguns resultados satisfatórios e precisos, o que mostra que as limitações não significam que o método de Croston não seja útil (Shenstone e Hyndman 2005).

Syntetos e Boylan (2001) demonstraram que o método de Croston é enviesado, devido ao rácio efetuado com a combinação das duas componentes dos dados e sugeriram em 2005 uma versão modificada conhecida como Aproximação de Syntetos-Boylan (SBA - Syntetos–Boylan *Approximation*), que resolve o problema de enviesamento (Syntetos e Boylan, 2005). Este método é uma adaptação do método de Croston que introduz um fator de amortecimento, multiplicativo, na equação da previsão. Com isto, o problema de enviesamento é ultrapassado, conseguindo que a equação de previsão seja aproximadamente não enviesada. No entanto, estudos mais recentes realizados por Teunter e Sani (2009) e Wallström e Segerstedt (2010) mostram que, apesar desta modificação, pode ainda surgir enviesamento quando a intermitência da série temporal em análise é baixa, ou seja, quando o número de zeros é reduzido. Shale *et al.* (2006) mostram que quando a procura ocorre pelo processo de Poisson a metodologia SBA deveria sofrer diferentes modificações para se tornar mais adequada.

Contudo, apesar do SBA apresentar melhor desempenho empírico do que o método original de Croston (Syntetos e Boylan, 2006) e resolver o problema do enviesamento, em 2011 Teunter, Syntetos e Babai (2011) observaram que os métodos anteriores não eram adequados para lidar com problemas de obsolescência, devido às atualizações das estimativas ocorrem apenas em períodos de procura não nula, e propuseram um novo método que designaram por TSB (Teunter, Syntetos e Babai). A preocupação com os problemas de obsolescência não tinha sido estudada até então, no entanto, trata-se de um interesse realista e exequível para os retalhistas, ou seja, a existência de um método que elimine problemas de obsolescência permite detetar quando um produto deixa de ser procurado pelos consumidores e isso possibilita ao retalhista tomar decisões o mais rapidamente possível para que não seja prejudicado, por exemplo, decisões sobre a manutenção ou cessação da venda do produto em questão. Este interesse é intensificado quando os produtos de natureza intermitente são considerados os com maior risco de obsolescência (Syntetos *et al.*, 2015). No método TSB, tal como no Croston, a série intermitente original é dividida em duas séries: a procura não nula e a probabilidade da procura, sendo estas estimadas usando SES. A probabilidade da procura pode apresentar o valor de um se ocorrer procura ou o valor de zero se não ocorrer procura. Neste método, a procura não nula é apenas atualizada quando

ocorre procura, enquanto a probabilidade da procura é continuamente estimada, atualizando-se no final de cada período (Kourentzes, 2014). Devido à presença desta atualização, o TSB permite que o valor da previsão se aproxime de zero em períodos contínuos de procura nula, sendo uma mais valia em relação a todos os métodos anteriores, pois esta informação permite através dos valores obtidos tomar decisões de gestão de *stocks* e vendas.

Nesta secção, até ao momento, foram apresentados os métodos de previsão de procura intermitente e a sua evolução ao longo dos anos. No entanto, estes métodos têm por base o alisamento exponencial e por isso nenhum detém modelos estatísticos subjacentes, traduzindo-se em limitações para a generalização, para a estimação correta dos parâmetros do modelo, para a média condicional e para a variância (Svetunkov e Boylan, 2017). É então necessário introduzir uma outra forma mais recente de expor estes métodos recorrendo aos modelos de espaço de estados.

Svetunkov (2017) propôs um modelo estatístico para dados intermitentes, estendendo a taxonomia dos modelos de alisamento exponencial, ou seja, os modelos de espaço de estados criados por Hyndman *et al.* (2008) que foram adaptados para dados intermitentes, através da derivação de um modelo de espaço de estados subjacente aos métodos explicitados anteriormente. Foi obtido através da introdução de uma variável binária (apresenta o valor de zero se ocorrer procura e o valor de um se não ocorrer procura) com distribuição de Bernoulli e com uma probabilidade de ocorrência de procura que pode variar no tempo. Existem diversas maneiras de modelar essa probabilidade:

- Modelo com probabilidade fixa. Este apresenta uma probabilidade de ocorrência fixa ao longo do tempo (Svetunkov e Boylan, 2017).
- Modelo com probabilidade de ocorrência baseada no método de Croston. Segue o modelo original proposto por Croston (1972) sendo a probabilidade inversamente proporcional ao número de instantes de tempo entre procura não nula. Uma variante deste é o modelo com probabilidade de ocorrência baseada na Aproximação Syntetos-Boylan.
- Modelo com probabilidade de ocorrência baseada no método TSB. Segue o modelo original proposto por Teunter, Syntetos e Babai (2011) com a probabilidade de ocorrência a variar ao longo do tempo.

O modelo desenvolvido por Svetunkov sustenta o método de Croston e o método TSB, sendo estes importantes para a gestão de *stocks*, pois as suas previsões são utilizadas para decisões de reposição ou descontinuação de *stock*. Este modelo apresenta uma grande flexibilidade, possibilitando a introdução de variáveis exógenas (por exemplo, as promoções)

e a sua aplicação tanto em previsões de *fast moving goods* como de *slow moving goods*, e por isso, incluir processos intermitentes e não intermitentes, alargando assim a taxonomia de Hyndman *et al.* (2008). Esta possibilidade de incluir ambos os processos no mesmo modelo é bastante importante do ponto de vista prático para a previsão de uma ampla gama de produtos, como é o caso do setor do retalho, pois estes podem evoluir de *fast moving goods* para *slow moving goods* e vice-versa. Uma outra vantagem deste modelo é a capacidade rigorosa de definição de parâmetros e a seleção de modelos de forma sistemática (Svetunkov e Boylan, 2017).

A segunda perspetiva diz respeito a um método proposto por Willemain *et al.* (2004), o método de *bootstrap*. Este utiliza amostras aleatórias de dados históricos de uma amostra maior ou de uma população, podendo estas serem diferentes entre si ou da própria população. Com estas amostras é construído um histograma de distribuição da procura de inventário durante o tempo de execução. Este método apresenta algumas vantagens, tais como a sua fácil modificação permitindo a acomodação de tempos de ligação variáveis, a atratividade por parte dos utilizadores, uma vez que o *bootstrap* depende dos dados históricos detalhados de cada item de inventário e não de suposições matemáticas e o fácil entendimento do procedimento por parte dos utilizadores, pois a sua natureza algorítmica de inferência computacional é mais facilmente entendida do que o carácter abstrato das abordagens matemáticas tradicionais para a inferência estatística. No entanto, apesar disto, este método apresenta dificuldades e problemas, como a criação de previsões fisicamente não significativas e a não estacionaridade, pois é assumido pelo método que a série de dados está estacionária ou facilmente se transporta para esse estado, não contemplando assim as tendências e sazonalidades dos dados. No caso do setor do retalho, alguns produtos apresentam claramente sazonalidade e por isso o uso deste método poderia não ser adequado. Em 2015, Syntetos *et al.* (2015) criaram o método WSS, uma forma avançada de *bootstrapping* e, nesse mesmo trabalho, compararam o seu desempenho com o de métodos paramétricos simples. Concluíram que o método de WSS de *bootstrapping* não melhora o controlo de *stock* em relação aos métodos paramétricos simples que apresentaram melhores resultados. O método de WSS de *bootstrapping* utiliza ajustes de julgamento que podem ser desnecessários ou prejudiciais quando aplicados com informação errada ou sem compreensão do processo de previsão, para além disso, este método necessita de maior potência computacional e maior conhecimento especializado. Segundo Kolassa (2016), os resultados apresentados por este método não justificam o tempo de execução adicional

relativamente aos outros, sendo uma conclusão importante para o setor do retalho, pois este utiliza grande número de séries temporais no processo de previsão. É então comprovado por Syntetos *et al.* (2015) que é necessária mais investigação para ampliar a capacidade do *bootstrapping* de forma a atingir melhores resultados.

Por último, a terceira perspetiva inclui a abordagem de três diferentes distribuições propostas por Snyder *et al.* (2012). Foca-se na distribuição de Poisson (como um *benchmark* amplamente utilizado), na binomial negativa (como extensão popular do Poisson) e na *hurdle shifted Poisson* (que retém a noção de Croston sobre o processo de Bernoulli para a ocorrência de procura de períodos ativos). Com a comparação destes modelos foi possível concluir que o planeamento de inventário deve basear-se em modelos dinâmicos que utilizem distribuições mais flexíveis que a tradicional Poisson. Para além disso, o SES apresenta um bom funcionamento em conjunto com uma distribuição binomial negativa sem restrições e o método de Croston deve ser substituído por alisamento exponencial, juntamente com uma distribuição binomial negativa. Kolassa (2016) corrobora parte deste estudo, defendendo que as previsões de venda no retalho não devem utilizar um modelo tradicional de Poisson, no entanto, contraria o que diz respeito ao bom desempenho das distribuições binomiais negativas, concluindo que modelar a procura associada a reduções de preços através de modelos dinâmicos binomiais negativos (amortizados ou não) ou de Poisson não produz melhores distribuições de previsão do que um modelo empírico simples.

É consensual na literatura que a primeira perspetiva apresentada é a mais estudada e desenvolvida, com um maior número de utilizações práticas nas diferentes indústrias para dados de natureza intermitente.

### 3. Metodologia

#### 3.1 Métodos de Previsão para Séries Intermitentes

##### Método Naïve

Uma série temporal é uma sequência de números indexados no tempo, habitualmente igualmente espaçados e ordenados, que pode identificar-se por  $y_1, y_2, \dots, y_T$ . O método naïve é um método de previsão de séries temporais muito simples. É, no entanto, bastante utilizado como método de referência (*benchmark*) e frequentemente até bastante eficaz. Este método assume que as previsões dos valores futuros são iguais ao último valor observado, tal como mostra a seguinte equação:

$$\hat{y}_{T+h|T} = y_T \quad (3.1)$$

onde  $\hat{y}_{T+h|T}$  é o valor da previsão para o instante  $T + h$ , com  $h = 1, 2, \dots$ , baseada nos dados históricos  $y_1, y_2, \dots, y_T$ . O método naïve sazonal é idêntico ao anterior, mas mais apropriado para séries temporais com sazonalidade (padrão de comportamento que se repete periodicamente por iguais períodos de tempo), e onde cada previsão é igual ao último valor observado do respetivo período homólogo:

$$\hat{y}_{T+h|T} = y_{T+h-m(k+1)} \quad (3.2)$$

onde  $m$  é o período sazonal e  $k$  é a parte inteira de  $(h - 1)/m$ . Por exemplo, para dados mensais, a previsão para valores futuros do mês de Janeiro é igual ao valor do último mês de Janeiro observado.

##### Método de Alisamento Exponencial Simples

Uma série temporal é habitualmente modelizada através dos seus padrões de comportamento que são a tendência (um longo período de crescimento ou decrescimento) e a sazonalidade. O método de alisamento exponencial simples (SES) é adequado para a previsão de séries temporais sem tendência e sazonalidade. As previsões são obtidas usando médias ponderadas, onde os pesos diminuem exponencialmente à medida que as observações se vão tornando mais antigas. Pode ser expresso da seguinte forma:

$$\hat{y}_{T+1|T} = \alpha y_T + (1 - \alpha) \hat{y}_{T|T-1} \quad (3.3)$$

onde a previsão para o instante  $T + 1$  é igual à média ponderada entre a última observação  $y_T$  e a última previsão  $\hat{y}_{T|T-1}$ , sendo  $0 \leq \alpha \leq 1$  o parâmetro de alisamento. Os valores ajustados dos dados históricos obtêm-se analogamente:

$$\hat{y}_{t+1|t} = \alpha y_t + (1 - \alpha) \hat{y}_{t|t-1}, \quad t = 1, 2, \dots, T.$$

ou ainda numa forma simplificada:

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha) \hat{y}_t, \quad t = 1, 2, \dots, T. \quad (3.4)$$

### Método de Croston

O método de previsão para procura intermitente mais conhecido foi proposto por Croston (1972) que notou, pela primeira vez, que quando a procura é intermitente o SES produz previsões enviesadas imediatamente após a ocorrência de procura. Assim, propôs considerar duas séries: os valores da procura e os intervalos de tempo entre procura não nula. O seu método tem a forma seguinte:

$$y_t = o_t z_t \quad (3.5)$$

onde  $o_t$  é uma variável aleatória com distribuição de Bernoulli tomando o valor 1 quando ocorre procura e 0 no caso contrário. Croston mostrou que a probabilidade de ocorrência de procura pode ser estimada usando os intervalos (instantes) de tempo entre procura não nula  $q_t$ . Utilizando SES para prever os valores da procura  $z_t$  e os intervalos de tempo entre procura não nula  $q_t$ , o seu método tem a forma seguinte:

$$\begin{aligned} \hat{y}_t &= \frac{1}{\hat{q}_t} \hat{z}_t \\ \hat{z}_t &= \alpha_z z_{t-1} + (1 - \alpha_z) \hat{z}_{t-1} \\ \hat{q}_t &= \alpha_q q_{t-1} + (1 - \alpha_q) \hat{q}_{t-1} \end{aligned} \quad (3.6)$$

onde  $\hat{y}_t$  é a procura média prevista,  $\hat{z}_t$  é o valor da procura prevista,  $\hat{q}_t$  é o intervalo de tempo entre procura não nula previsto e  $\alpha_z$  e  $\alpha_q$  são os parâmetros de alisamento, respetivamente de  $z_t$  e  $q_t$ . Note-se que a atualização de  $\hat{z}_t$  e  $\hat{q}_t$  só ocorre quando  $o_t = 1$ . Quando  $o_t = 0$ , tem-se  $\hat{z}_t = \hat{z}_{t-1}$  e  $\hat{q}_t = \hat{q}_{t-1}$ .

### Aproximação de Syntetos-Boylan

Syntetos e Boylan (2001) demonstraram que o método de Croston é enviesado e por forma a corrigi-lo propuseram a seguinte aproximação, conhecida por Aproximação de Syntetos-Boylan (SBA):

$$\hat{y}_t = \left(1 - \frac{\alpha_q}{2}\right) \frac{1}{\hat{q}_t} \hat{z}_t. \quad (3.7)$$

### Método TSB

Apesar do método SBA apresentar melhor performance empírica do que o método de Croston, em 2011 Teunter, Syntetos e Babai (2011) observaram que estes não lidavam bem com problemas de obsolescência e propuseram o método conhecido por TSB. Os autores mantiveram o princípio (Equação 3.5) de Croston, estimando a probabilidade de ocorrência de procura, variante no tempo,  $p_t$ , com base na variável  $o_t$ , utilizando SES:

$$\begin{aligned} \hat{y}_t &= \hat{p}_t \hat{z}_t \\ \hat{z}_t &= \alpha_z z_{t-1} + (1 - \alpha_z) \hat{z}_{t-1} \\ \hat{p}_t &= \alpha_p o_{t-1} + (1 - \alpha_p) \hat{p}_{t-1} \end{aligned} \quad (3.8)$$

onde  $\hat{p}_t$  é a probabilidade de ocorrência de procura prevista e  $\alpha_p$  o respetivo parâmetro de alisamento. A atualização da probabilidade  $\hat{p}_t$  é efetuada em cada instante de tempo. A atualização do valor da procura  $\hat{z}_t$  só ocorre quando  $o_t = 1$ . Quando  $o_t = 0$  tem-se  $\hat{z}_t = \hat{z}_{t-1}$ .

## 3.2 Modelos de Espaço de Estados para Séries Intermitentes

Svetunkov e Boylan (2017) iniciam a sua investigação com a formulação original de Croston (1972) (Equação 3.5) dividindo a procura intermitente de forma semelhante, mas,



assumem que  $z_t$  é gerado usando um modelo estatístico próprio. Considerando que, quer o método de Croston quer o método TSB utilizam o método de alisamento exponencial, Svetunkov e Boylan (2017) propuseram um modelo para  $z_t$  que tem por base estas abordagens de previsão. Trata-se de um modelo de espaço de estados com uma única fonte de erro cuja formulação geral é (Svetunkov e Boylan, 2017):

$$\begin{aligned} y_t &= o_t z_t \\ z_t &= \omega(\mathbf{v}_{t-1}) + r(\mathbf{v}_{t-1})\varepsilon_t \\ \mathbf{v}_t &= f(\mathbf{v}_{t-1}) + g(\mathbf{v}_{t-1})\varepsilon_t \end{aligned} \quad (3.9)$$

onde  $o_t$  é uma variável aleatória com distribuição de Bernoulli,  $\mathbf{v}_t$  é o vetor de estados,  $\varepsilon_t$  é o termo do erro,  $f(\cdot)$  é a função de transição,  $\omega(\cdot)$  é a função de observação,  $g(\cdot)$  é a função persistente e  $r(\cdot)$  é a função do termo do erro. Atente-se que a primeira equação corresponde à formulação original de Croston (1972) (Equação 3.5), a segunda equação, designada por equação da observação, reflete a evolução do potencial valor da procura ao longo do tempo e a terceira equação corresponde à equação da transição usual do modelo de espaço de estados (Hyndman *et al.*, 2008), descrevendo a evolução das componentes do modelo (nível, tendência e sazonalidade) ao longo do tempo. Uma grande vantagem desta formulação é que no caso de bens do tipo *fast moving goods*  $o_t$  é igual a um para todo o  $t$ , passando (Equação 3.9) a ser um modelo de espaço de estados usual, utilizado habitualmente em séries não intermitentes. Por exemplo, o modelo de espaço de estados com erros aditivos e apenas a componente do nível, baseado no método de alisamento exponencial simples, é (Hyndman *et al.*, 2008):

$$\begin{aligned} y_t &= l_{t-1} + \varepsilon_t \\ l_t &= l_{t-1} + \alpha \varepsilon_t \end{aligned} \quad (3.10)$$

onde  $y_t$  é o valor da série no instante  $t$ ,  $l_t$  é a componente do nível no instante  $t$ ,  $\varepsilon_t \sim NID(0, \sigma^2)$  é o termo do erro com distribuição normal e  $\alpha$  é o parâmetro de alisamento. Este modelo obtém-se fazendo  $\omega = [1]$ ,  $F = [1]$ ,  $g = \alpha$  e  $\mathbf{v}_t = l_t$  na formulação (Equação 3.9). O modelo de espaço de estados com erros aditivos e as componentes do nível e da tendência (aditiva) é (Hyndman *et al.*, 2008):

$$\begin{aligned}
y_t &= l_{t-1} + b_{t-1} + \varepsilon_t \\
l_t &= l_{t-1} + b_{t-1} + \alpha \varepsilon_t \\
b_t &= b_{t-1} + \beta \varepsilon_t
\end{aligned} \tag{3.11}$$

onde  $b_t$  é a componente da tendência no instante  $t$  e  $\beta$  é o respetivo parâmetro de alisamento. O modelo de espaço de estados com erros aditivos e as componentes do nível, da tendência e da sazonalidade (aditivas) é (Hyndman *et al.*, 2008):

$$\begin{aligned}
y_t &= l_{t-1} + b_{t-1} + s_{t-m} + \varepsilon_t \\
l_t &= l_{t-1} + b_{t-1} + \alpha \varepsilon_t \\
b_t &= b_{t-1} + \beta \varepsilon_t \\
s_t &= s_{t-m} + \gamma \varepsilon_t
\end{aligned} \tag{3.12}$$

onde  $s_t$  é a componente da sazonalidade no instante  $t$  e  $\gamma$  é o respetivo parâmetro de alisamento. Os modelos de espaço de estados são habitualmente designados por ETS(., ., .) para (Erro, Tendência, Sazonalidade). As possibilidades para cada uma destas componentes são *Erro* = {A,M} (aditivo ou multiplicativo), *Tendência* = {N,A,A<sub>d</sub>,M,M<sub>d</sub>} (sem, aditiva, aditiva amortecida, multiplicativa ou multiplicativa amortecida) e *Sazonalidade* = {N,A,M} (sem, aditiva ou multiplicativa). Assim, o modelo em (Equação 3.10) é um ETS(A,N,N), o modelo em (Equação 3.11) é um ETS(A,A,N) e o modelo em (Equação 3.12) é um ETS(A,A,A).

Os modelos multiplicativos puros (todas as componentes se multiplicam na equação da observação) são mais adequados do que os modelos aditivos (todas as componentes se adicionam na equação da observação) ou mistos (há componentes aditivas e multiplicativas na equação da observação) para a modelação de procura intermitente, visto que restringem os valores da mesma a números positivos.

Assim, neste trabalho optou-se pelos modelos iETS(M,N,N), iETS(M,M,N), e iETS(M,M<sub>d</sub>,N) para modelizar o valor da procura intermitente, tal como recomendam Svetunkov e Boylan (2017). A letra “i” é utilizada para distinguir os modelos intermitentes dos convencionais. A sazonalidade não foi considerada visto que na análise exploratória das séries dos dados mostrou-se pouco relevante. Assim, a formulação geral apresentada em (Equação 3.9) reduz-se, no nosso caso, aos modelos particulares seguintes, que correspondem, respetivamente, aos modelos iETS(M,N,N), iETS(M,M,N), e iETS(M,M<sub>d</sub>,N):

$$\begin{aligned}
y_t &= o_t z_t \\
z_t &= l_{t-1}(1 + \varepsilon_t) \\
l_t &= l_{t-1}(1 + \alpha \varepsilon_t) \\
o_t &\sim \text{Bernoulli}(p_t)
\end{aligned} \tag{3.13}$$

$$\begin{aligned}
y_t &= o_t z_t \\
z_t &= l_{t-1} b_{t-1}(1 + \varepsilon_t) \\
l_t &= l_{t-1} b_{t-1}(1 + \alpha \varepsilon_t) \\
b_t &= b_{t-1}(1 + \beta \varepsilon_t) \\
o_t &\sim \text{Bernoulli}(p_t)
\end{aligned} \tag{3.14}$$

$$\begin{aligned}
y_t &= o_t z_t \\
z_t &= l_{t-1} b_{t-1}^\phi b_{t-1}(1 + \varepsilon_t) \\
l_t &= l_{t-1} b_{t-1}^\phi(1 + \alpha \varepsilon_t) \\
b_t &= b_{t-1}^\phi(1 + \beta \varepsilon_t) \\
o_t &\sim \text{Bernoulli}(p_t)
\end{aligned} \tag{3.15}$$

onde  $(1 + \varepsilon_t)$  são independentes e identicamente distribuídos com distribuição log-normal com parâmetros  $\mu_\varepsilon$  e  $\sigma_\varepsilon^2$ :  $(1 + \varepsilon_t) \sim \log N(\mu_\varepsilon, \sigma_\varepsilon^2)$ . Habitualmente assume-se que  $\mu_\varepsilon$  é igual a zero por forma a que a distribuição tenha média nula. A estimação dos parâmetros destes modelos é efetuada através da maximização da verosimilhança. Os detalhes sobre esta maximização podem ser encontrados em Svetunkov e Boylan, (2017).

A única variável ainda por estimar é a probabilidade de ocorrência de procura  $p_t$ , que pode ser modelizada de diferentes formas. No caso mais simples pode assumir-se que esta probabilidade é um valor fixo, significando que:

$$o_t \sim \text{Bernoulli}(p) \tag{3.16}$$

A probabilidade  $p$  pode ser estimada através da maximização da verosimilhança (Svetunkov e Boylan, 2017) com:

$$\hat{p} = \frac{T_1}{T} \quad (3.17)$$

sendo  $T$  o número total de observações e  $T_1$  o número de observações não nulas. Esta formulação, conjugada com um dos modelos (Equação 3.13), (Equação 3.14) ou (Equação 3.15), é designada por Svetunkov e Boylan (2017) por iETS(M,Y,N)f. No método de Croston assume-se que a probabilidade de ocorrência de procura  $p_t$  varia no tempo e é inversamente proporcional aos intervalos de tempo entre procura não nula  $q_t$ , ou seja

$$p_t = \frac{1}{q_t} \quad (3.18)$$

O cálculo de  $q_t$  inicia com um e entre procura consecutiva não nula  $q_t = 1$ . A probabilidade de ocorrência é atualizada quando o valor da procura é não nulo. Longos períodos de procura nula conduzem a uma probabilidade de ocorrência baixa. Como já foi referido, Croston (1972) utilizou SES para prever  $q_{t+h}$ , pelo que faz sentido optar por um dos seguintes modelos: ETS(A,N,N) ou ETS(M,N,N) para modelizar  $q_t$ . Uma vez que  $p_t \in [0,1]$ , é preferível optar pelo modelo multiplicativo uma vez que nesse caso  $q_t$  está restrito a valores positivos. Assim, a probabilidade de ocorrência de procura, formulada tendo por base o método de Croston, vem na forma seguinte (Svetunkov e Boylan, 2017):

$$\begin{aligned} o_t &\sim \text{Bernoulli}\left(\frac{1}{\lfloor q_t \rfloor}\right) \\ q_t &= l_{q,t-1}(1 + \varepsilon_{q,t}) \\ l_{q,t} &= l_{q,t-1}(1 + \alpha_q \varepsilon_{q,t}) \\ (1 + \varepsilon_{q,t}) &\sim \log N(0, \sigma_q^2) \end{aligned} \quad (3.19)$$

onde  $l_{q,t}$  é a componente do nível para intervalos de tempo entre procura não nula,  $\alpha_q$  é o parâmetro de alisamento e  $\varepsilon_{q,t}$  é o termo do erro. Este modelo, conjugado com um dos modelos (Equação 3.13), (Equação 3.14) ou (Equação 3.15), é designado por Svetunkov e Boylan (2017) por iETS(M,Y,N)i. É importante notar que apesar dos intervalos  $q_t$  poderem variar em cada instante de tempo, influenciado a correspondente probabilidade  $\frac{1}{\lfloor q_t \rfloor}$ , o modelo iETS(M,Y,N)i não pode ser estimado quando a procura é nula. Assim, durante a sua

estimação assume-se que os estados de  $q_t$  (neste caso o nível) não variam se a procura for nula. Este pressuposto pode ser artificial mas segue a lógica do método original de Croston (Svetunkov e Boylan, 2017). Como vimos anteriormente, no caso do método TSB a probabilidade de ocorrência de procura, variante no tempo,  $p_t$  é estimada com base na variável  $o_t$ . Seguindo um raciocínio análogo ao efetuado para a formulação do modelo iETSi, o modelo para a probabilidade de ocorrência de procura formulado tendo por base o método de TSB é (Svetunkov e Boylan, 2017):

$$\begin{aligned} o_t &\sim \text{Bernoulli}(p_t) \\ p_t &= l_{p,t-1}(1 + \varepsilon_{p,t}) \\ l_{p,t} &= l_{p,t-1}(1 + \alpha_p \varepsilon_{p,t}) \\ (1 + \varepsilon_{p,t}) &\sim \log N(0, \sigma_p^2) \end{aligned} \quad (3.20)$$

onde  $l_{p,t}$  é a componente do nível para a probabilidade de ocorrência de procura,  $\alpha_p$  é o parâmetro de alisamento e  $\varepsilon_{p,t}$  é o termo do erro. Este modelo, conjugado com um dos modelos (Equação 3.13), (Equação 3.14) ou (Equação 3.15), é designado por Svetunkov e Boylan (2017) por iETS(M,Y,N)p. Nesta *framework*, para cada um dos casos, a escolha de um dos modelos (Equação 3.13), (Equação 3.14) ou (Equação 3.15) pode ser efetuada usando um critério de informação. Por exemplo, o valor do critério de informação de Akaike é:

$$\text{AIC} = 2k - 2l(\theta, \hat{\sigma}_\varepsilon^2 | y), \quad (3.21)$$

onde  $\theta$  são os parâmetros do modelo,  $k$  é o número de parâmetros em  $\theta$  mais um (para incluir a variância dos erros  $\hat{\sigma}_\varepsilon^2$ ) e  $l(\cdot)$  é a função verosimilhança. Caso os valores iniciais dos estados sejam determinados durante o processo de otimização de  $l(\cdot)$ ,  $k$  inclui também o número desses parâmetros.

### Introdução de variáveis exógenas

Os modelos de espaço de estados para séries intermitentes possuem a flexibilidade de introduzir variáveis exógenas de acordo com a seguinte formulação:

$$\begin{aligned} y_t &= o_t z_t \\ z_t &= \omega(\mathbf{v}_{t-1}) + a'_{t-1} x_t + r(\mathbf{v}_{t-1}) \varepsilon_t \end{aligned} \quad (3.22)$$

$$\begin{aligned}\mathbf{v}_t &= f(\mathbf{v}_{t-1}) + g(\mathbf{v}_{t-1})\varepsilon_t \\ a_t &= F_x a_{t-1} + g_x x_t^{-1} \varepsilon_t\end{aligned}$$

onde  $\mathbf{a}_t$  é o vetor dos parâmetros variáveis no tempo para o vetor das variáveis exógenas  $\mathbf{x}_t$ ,  $F_x$  é a matriz de transição das variáveis exógenas,  $g_x$  o vetor de persistência das variáveis exógenas e  $\mathbf{x}_t^{-1}$  o vetor do inverso das variáveis exógenas. Caso se assuma que os parâmetros não deverão variar no tempo então  $g_x = \mathbf{0}$ . Svetunkov e Boylan (2017) designam modelos de espaço de estados intermitentes por iETSX.

### 3.3 Multiple Aggregation Prediction Algorithm

O método iMAPA é uma versão alterada do método MAPA (*Multiple Aggregation Prediction Algorithm*) para dados de natureza intermitente, baseando-se na agregação ou desagregação dos dados de forma a reduzir ou eliminar totalmente o número de zeros na procura (transformando-se em séries não intermitentes), produzindo dessa forma melhores resultados de previsão.

O MAPA, com níveis de agregação temporal, produz previsões para instantes futuros através da combinação das componentes (nível, tendência e sazonalidade) das séries temporais, com a execução de três fases: a agregação, a previsão e a combinação (Anexo 2). Na primeira fase os dados são agregados em vários níveis de agregação através da criação de conjuntos consecutivos de valores da série temporal original de tamanho  $k$ . Em vez da soma, é utilizada a média, uma vez que retém a escala das séries nos diferentes níveis de agregação. A agregação temporal pode ser realizada da seguinte forma, para uma série temporal  $\mathbf{y}$ , observações  $y_t$  e instante temporal de 1 até  $n$ :

$$y_i^{[k]} = k^{-1} \sum_{t=1+(i-1)k}^{ik} y_t \quad (3.23)$$

Com isto, os componentes de alta frequência são progressivamente filtrados à medida que o nível de agregação aumenta, atenuando essencialmente a componente sazonal e aleatória das séries temporais, permitindo que as componentes de tendência e nível de baixa frequência dominem. No final desta fase, através da agregação temporal, são produzidas  $K$  séries temporais. Na segunda fase, são atribuídos modelos de previsão de forma adequada para cada  $y^{[k]}$  produzidos na primeira fase. Por fim, na terceira fase, os diversos componentes

produzidos nas fases anteriores são combinados separadamente para produzir os estimadores finais de nível, tendência e sazonalidade, que são posteriormente utilizados para produzir as previsões finais.

Sendo o iMAPA uma versão modificada do método original, baseia-se na agregação e desagregação das séries temporais originais, na seleção de métodos adequados (utilizando esquemas de classificação) e na combinação de previsões. Este método produz várias agregações temporais, produzindo dados de níveis de agregação diferentes com diferentes características e com isso diferentes previsões para o mesmo produto, que são combinadas num valor final de previsão. Dado que o grau de intermitência varia nos diferentes níveis de agregação, podendo até atingir o grau zero, é utilizado uma forma de seleção de métodos (esquema de classificação), de forma a selecionar os métodos mais adequados para cada nível de agregação, de acordo com as características distintas de cada nível.

Recentemente, foi proposto na literatura por Kourentzes e Petropoulos (2016) uma extensão do modelo MAPA que permite a inclusão de variáveis exógenas quer para dados do tipo *fast moving goods* quer para dados do tipo *slow moving goods*. O processo inicia-se com a agregação temporal das séries e das variáveis exógenas, onde os dados são processados em cada nível de agregação segundo o fluxograma apresentado no Anexo 3, ou seja, as variáveis exógenas são processadas primeiro através da análise de componentes principais e, em seguida, incorporadas no alisamento exponencial. A partir disso, o nível, a tendência e os componentes sazonais, bem como o efeito das variáveis exógenas, são extraídos. São combinadas as estimativas de todos os níveis de agregação temporal para cada nível, tendência, sazonalidade e componentes de projeção e por fim estes são combinados na previsão final através da seguinte equação:

$$\hat{y}_{t+h}^{[1]} = \bar{l}_{t+h} + \bar{b}_{t+h} + \bar{s}_{t-m+h} + \sum_{k=1}^K \bar{d}_{j,t+h} \quad (3.24)$$

## 4. Caso de Estudo


### 4.1. Grupo Jerónimo Martins

O Grupo Jerónimo Martins surgiu em 1792 com a abertura de uma loja no Chiado, por um jovem empreendedor proveniente da Galiza, Jerónimo Martins. Durante todo o século XIX a loja prosperou ganhando fama e reputação, sendo comprada em 1920 por empresários do Porto. Em 1938 o Grupo sofreu uma viragem estratégica na sua atividade, apostando na área industrial e apenas 11 anos depois realizou uma parceria com a Unilever. Em 1978 deu-se o início da distribuição moderna, tendo o Grupo entrado no negócio da distribuição alimentar com a criação do Pingo Doce, 10 anos depois. No sentido de acompanhar a sociedade moderna, foi o primeiro supermercado com loja online em Portugal. O Grupo Jerónimo Martins deu o primeiro passo na internacionalização, acreditando que a Polónia seria o melhor país, pelos seus 40 milhões de habitantes e pela sua situação económica, tendo surgido as lojas Biedronka, que neste momento são líderes de mercado na distribuição alimentar na Polónia. Com o crescimento e estabilidade do Grupo, em 2011, definiram a sua expansão para a Colômbia com a criação dos supermercados Ara (Jerónimo Martins, 2016).

Assim, passados 225 anos, este Grupo apresenta-se em três países localizados em dois continentes diferentes. Afirmam ser “um Grupo internacional comprometido em ser português em Portugal, polaco na Polónia e colombiano na Colômbia” (Jerónimo Martins, 2018b), conseguindo com a sua cobertura geográfica garantir a proximidade junto dos seus consumidores. Operam nos setores de distribuição alimentar e do retalho especializado. No entanto, é a distribuição alimentar que representa 95% das vendas do Grupo Jerónimo Martins, sendo considerada a principal atividade da empresa (Jerónimo Martins, 2018a). O retalho especializado inclui a Hussel, Jeronymo e Hebe. Em Portugal operam as cafetarias Jeronymo e Hussel, e na Polónia detêm uma cadeia de 182 *drugstores* Hebe. A distribuição alimentar inclui a Biedronka, Ara, Recheio e Pingo Doce. A Biedronka é uma cadeia de lojas de alimentos na Polónia que detém a liderança do mercado de retalho alimentar. Com 2823 lojas, combina uma variedade de produtos com o ambiente local e de proximidade praticando os preços mais competitivos do mercado. Com a mais recente expansão, na Colômbia, existem 389 lojas Ara, uma cadeia de lojas de alimentação de proximidade, reputada pela qualidade ao melhor preço, combinando competitividade com campanhas promocionais. O Pingo Doce e o Recheio lideram o setor em Portugal. No ano de 2017, tal como indica o Gráfico 4, as vendas do Grupo Jerónimo Martins por área de negócio são lideradas pela



Biedronka, sendo que nesse mesmo ano, a Jerónimo Martins superou todos os seus recordes de vendas totais atingindo um valor de 16 276 milhões de euros, reforçou as quotas de mercado nos três países e manteve a solidez financeira, apresentando investimentos na ordem dos 724 milhões de euros e lucros de 385 milhões de euros (REN e Jerónimo Martins, 2017).




Fonte: REN e Jerónimo Martins (2017)

Gráfico 4. Vendas Jerónimo Martins por área de negócio 2017

Em Portugal são líderes do setor, com 510 lojas, mais de 30 000 colaboradores e com vendas conjuntas superiores a 4 600 milhões de euros em 2017. Como referido, em Portugal, o retalho especializado é composto por 24 lojas Hussel e 21 lojas Jeronymo, as vendas de ambas em 2017 aumentaram em relação ao ano anterior, com crescimentos *like-for-like*.

Contudo, a sua atividade principal é o setor do retalho e do grosso, sendo líder da distribuição alimentar em Portugal com 422 lojas Pingo Doce e 43 lojas de *cash & carry* Recheio, que representam 30% da faturação total do Grupo Jerónimo Martins. No ano de 2017, as vendas do Recheio aumentaram cerca de 7,2% e acredita-se que continuará nesse sentido devido aos fortes investimentos em políticas de preços e promoções efetuadas (Dinheiro Vivo, 2018a). O Pingo Doce com 422 lojas dispersas por mais de 300 localidades Portuguesas é a cadeia líder de supermercados. As suas vendas aumentaram ao longo dos últimos anos, como podemos visualizar no Gráfico 5, alcançando em 2017 mais de 700 000 visitas diárias, vendas no valor de 3 667 milhões de euros e um EBITDA de 188 milhões de euros, menos 1,6% do que em 2016, com uma margem de 5,1% (abaixo dos 5,4% registados em 2016), sendo esta descida justificada pela revisão realizada dos pacotes remuneratórios das equipas, que acreditam trazer melhorias na eficiência e qualidade de serviços (Dinheiro Vivo, 2018a; Jerónimo Martins, 2018c).



Fonte: Kia Motors Corporation (2016) e Jerónimo Martins (2018c)

Gráfico 5. Vendas Pingo Doce de 2012 a 2017

No entanto, no ano de 2017, o Pingo Doce continuou a crescer no setor do retalho, com abertura de novas lojas e devido à forte tendência dos consumidores para as promoções, manteve a sua estratégia comercial de preço competitivos combinados com intensas campanhas promocionais. Como o DinheiroVivo (2018a) noticiou, a Jerónimo Martins afirma que “o Pingo Doce manterá o foco nos seus pilares de diferenciação como forma de continuar a ganhar quota de mercado”, praticando uma estratégia de *High Low Pricing* (HILO), com práticas promocionais frequentes, distinguindo-se com os produtos frescos de elevada qualidade e variedade, com a sua marca própria Pingo Doce que mantém uma boa relação qualidade/preço, com as *meals solutions* adequadas aos hábitos alimentares de cada consumidor, com a sua política de preços competitiva com oportunidades de poupança imediata e com um ambiente de loja único e de qualidade (Jerónimo Martins, 2018d). No futuro, o Pingo Doce continuará a focar-se naquilo que o diferencia, fomentando o investimento, estando previsto para 2018 um investimento de cerca de 130 milhões de euros para abertura de 10 novas lojas (Dinheiro Vivo, 2018b).

#### 4.2. Conjunto de Dados

Neste trabalho pretende-se estudar a previsão da procura de *slow moving goods* do setor de retalho sob efeito de ações promocionais. Para efetuar a previsão de vendas utilizam-se os modelos de espaço de estados para dados intermitentes introduzidos por Svetunkov e Boylan (2017). Para o efeito utiliza-se um conjunto de dados diários relativos às vendas de

doze lojas Pingo Doce do Grupo Jerónimo Martins de várias dimensões, durante um período de cerca de três anos e meio (de 3 de Janeiro de 2012 a 27 de Abril de 2015). Os dados disponibilizados para cada loja incluem informação relativa ao número de unidades vendidas de cada produto (SKU – *Stock Keeping Unit*), a categoria do SKU e informação promocional, designadamente a percentagem de promoção.

É importante referir a diversidade e o elevado número de séries temporais envolvido, que permitem uma avaliação eficaz do desempenho de métodos e modelos de previsão, e por sua vez a obtenção de resultados mais consistentes. Atente-se que são escassos os estudos de previsão de dados de natureza intermitente, não existindo estudos do género com dados práticos de um retalhista, tendo o presente trabalho a mais valia adicional de introduzir variáveis exógenas no processo de modelação. Com isto pretende-se melhorar o sistema de previsão de vendas dos retalhistas e definir os modelos mais adequados num contexto promocional, por forma a diminuir perdas incorridas por falta ou excesso de *stock*.

No âmbito da realização deste trabalho, os dados fornecidos pelo Grupo Jerónimo Martins foram estudados, processados, analisados e tratados para que fosse possível levar a cabo um trabalho rigoroso e adequado. O tratamento dos dados passou por duas grandes fases. Os dados fornecidos diziam respeito a doze lojas Pingo Doce de três regiões diferentes de Portugal com três dimensões distintas. Numa fase inicial os produtos das doze lojas foram separados em catorze áreas como podemos ver na Tabela 1, onde é apresentada a área, o número de SKUs de cada área e a percentagem de produtos de cada área no total da amostra. Posteriormente, destas catorze áreas, que incluem 129 081 SKUs, foram selecionadas apenas seis áreas principais (as primeiras seis apresentadas na Tabela 1) pois, estas representam cerca de 93% do volume total de vendas diárias das doze lojas, incluindo um total de 24 316 SKUs.

Para além disso, os dados sofreram uma agregação temporal, tratando-se inicialmente de vendas por SKU referentes a 1211 dias, passando a dados de vendas por SKU serem relativos a 173 semanas, sendo que esta alteração permitiu a diminuição do grau de intermitência dos dados. Com isto, terminamos a fase inicial com dados de vendas semanais por SKU, separados por loja, havendo uma organização globalizada dos produtos por categorias em cada loja.

Área	Nº de SKUs	Percentagem
Perecíveis especializados	6302	4,9%
Mercearia	6217	4,8%
Perecíveis não especializados	3682	2,9%
Produtos Pessoais	3606	2,8%
Detergentes e produtos limpeza	2514	1,9%
Bebidas	1995	1,5%
Têxtil	84 044	65%
Bazar ligeiro	9778	7,6%
Elétricos e entretenimento	6202	4,8%
Negócios complementares	4302	3,3%
Têxtil JM	339	0,26%
Serviços	86	0,0666%
Artigos retornáveis	11	0,0085%
Economato	3	0,002324%
<b>Total</b>	<b>129 081</b>	<b>100%</b>

Fonte: Base de dados Grupo Jerónimo Martins

Tabela 1. Número de SKUs por área e respetiva percentagem

Numa segunda fase, foi escolhida para estudo e análise apenas uma das lojas de maior dimensão, uma vez que esta apresentava a maior quantidade e valor de vendas, com 20 369 SKUs nas 6 áreas identificadas na fase anterior. Tal como mencionado anteriormente, neste trabalho pretende-se estudar a previsão da procura de *slow moving goods*, sendo as séries temporais em causa intermitentes, ou seja, contendo pelo menos um zero. Neste caso concreto, tratando-se de dados semanais, estas séries representam produtos que não vendem todas as semanas. Assim, foi necessário selecionar quais dos 20 369 SKUs em análise são não intermitentes, tendo-se considerado os seguintes critérios:

- Excluir séries que não apresentam nenhum zero, ou seja, produtos que vendem todas as semanas, existindo 988 SKUs deste tipo;
- Excluir séries de produtos que saíram da prateleira, ou seja, produtos que apresentam vendas positivas ao longo da série, mas que a partir de certa altura apresentam sempre valor zero até à última observação, existindo 1 236 SKUs deste tipo.

- Excluir dados de produtos que entraram em prateleira, ou seja, que apresentam vendas zero durante algum tempo, e após serem expostos na prateleira as suas vendas apresentam sempre valores positivos, existindo 3 683 SKUs deste tipo.

Esta seleção permitiu identificar 14 462 SKUs cujas vendas apresentam uma natureza intermitente nas 173 semanas consideradas.

A precisão das previsões de um método só pode ser determinada avaliando o seu desempenho com dados novos, que não foram utilizados na sua estimação. Logo, para a escolha do método mais adequado, é realizada uma separação dos dados históricos em duas partes: uma parte inicial dos dados forma o conjunto de treino e os dados restantes formam o conjunto de teste, tal como mostra a Figura 1. O conjunto de treino é utilizado para estimar os parâmetros do método de previsão e o conjunto de teste é utilizado para medir a precisão das suas previsões, pois é possível determinar se os valores obtidos são próximos ou não dos valores reais, ou seja, dos dados de teste.



Fonte: Hyndman e Athanasopoulos (2018)

Figura 1. Conjunto de treino e conjunto de teste

Habitualmente, o tamanho do conjunto de teste representa cerca de 20% a 30% do total de observações da série, mas esse valor pode variar em função do número total de observações disponíveis e do horizonte temporal de previsão pretendido, sendo que o conjunto de teste deverá ter no mínimo a mesma dimensão do horizonte de previsão máximo requerido (Hyndman e Athanasopoulos, 2018).

No caso em estudo, o conjunto de treino foi especificado com 139 semanas e o conjunto de teste, corresponde a cerca de 20% do tamanho total das séries, com 34 semanas. A especificação dos conjuntos de treino e teste levou à exclusão das séries que tinham o valor zero em todo o conjunto de teste exceto na última observação, existindo 6 356 SKUs deste tipo. Desta forma, a seleção de SKUs com natureza intermitente ficou atualizada em 8106.

Neste trabalho pretende-se também avaliar o impacto da introdução de informação adicional no desempenho da previsão. Para isso confrontar-se-á a performance dos modelos de espaço de estados com e sem variáveis exógenas. No caso dos modelos com variáveis

exógenas incluiu-se informação promocional relativa ao SKU. Não foi fornecida pelo Grupo Jerónimo Martins qualquer informação relativa às promoções dos SKUs, tendo sido efetuado o cálculo das promoções diárias com base na evolução do PVP ao longo do tempo. Assumiu-se a existência de uma promoção se o preço diminuiu pelo menos 10% num intervalo máximo de 15 dias, criando-se uma variável com o número de dias da semana em que a promoção esteve em vigor. Desta forma, as promoções são todas caracterizadas como reduções de preço, mesmo no caso de promoções do tipo leve 3 pague 2 ou outros tipos existentes. Para identificar as promoções foi utilizada uma variável binária, que tem o valor 1 se nessa semana o produto esteve em promoção, ou 0 no caso contrário.

Como exemplo apresentam-se no Anexo 4 gráficos de seis séries de vendas semanais, preços e promoções de seis SKUs com características distintas, nos quais as vendas correspondem à linha a preto e o preço à linha azul. São visíveis os zeros em todas as séries, ou seja, existem semanas em que as vendas são nulas. Para além disso, mostram-se séries com e sem existência de promoções, identificadas nos gráficos através de linhas verticais tracejadas. A primeira série apresenta um elevado número de promoções (observe-se o decréscimo de preço) e as vendas são fortemente alavancadas por estas. Na segunda e terceira séries observa-se uma atividade promocional menos intensa do que no primeiro caso. Na quarta série a maioria das promoções não tem um impacto significativo nas vendas. Em relação a séries sem promoção, temos o exemplo da quinta, onde as vendas se mantêm elevadas mesmo com o preço alto e sem promoções. Por fim, na última série é notória a existência de uma só promoção que ocorreu genericamente para todos os produtos no dia 1 de Maio de 2012.

Todo o procedimento experimental foi realizado utilizando o *software* estatístico livre R e os pacotes de previsão de séries temporais “Smooth” e “tsintermittent”. O processamento para obtenção dos resultados foi realizado com recurso à GridFEUP que disponibiliza à comunidade académica da UP um serviço de *High Performance Computing*.

### **4.3. Avaliação do Desempenho da Previsão**

Foi necessário medir a precisão das previsões dos modelos e métodos utilizados tendo, para isso, sido calculadas medidas de avaliação de desempenho adequadas para séries intermitentes. Por forma a ser possível calcular a média dos erros de previsão para todos os SKUs, cada erro foi escalado usando o valor médio do conjunto de treino da respetiva série.

Assim, o erro absoluto escalado (*scaled Absolute Error* - sAE) para a série  $i$  e horizonte  $h$  é dado por

$$sAE_{i,h} = \frac{|y_{N+h} - \hat{y}_h|}{\frac{1}{N} \sum_{t=1}^N y_t} \quad (4.1)$$

onde,  $N$  é o número de observações do conjunto de treino,  $y_{N+h}$  é o valor real observado no instante  $N + h$  correspondente à posição  $h$  no conjunto de teste e  $\hat{y}_h$  é a previsão  $h$ -passos à frente. Esta nomenclatura prevalece para as restantes fórmulas desta secção. Uma vez que o numerador e o denominador envolvem valores expressos na escala dos dados da série,  $sAE_{i,h}$  é adimensional, ou seja, independente da escala. O erro absoluto escalado médio (*scaled Mean Absolute Error* - sMAE) é obtido calculando a média dos erros absolutos escalados de todas as séries, relativos a cada horizonte  $h$ . O sMAE é apropriado para avaliar o desempenho dos modelos e métodos em termos de magnitude do enviesamento das estimativas.

Para se avaliar a performance dos modelos e métodos em termos de variância do enviesamento das estimativas pode utilizar-se o erro quadrático escalado (*scaled Squared Error* - sSE) que para a série  $i$  e horizonte  $h$  é dado por:

$$sSE_{i,h} = \left( \frac{y_{N+h} - \hat{y}_h}{\frac{1}{N} \sum_{t=1}^N y_t} \right)^2 \quad (4.2)$$

O erro quadrático escalado médio (*scaled Mean Squared Error* - sMSE) é obtido calculando a média dos erros quadráticos escalados de todas as séries, relativos a cada horizonte  $h$ . Hyndman e Koehler (2006) propuseram escalar o erro com o MAE relativo ao conjunto de treino de um método básico de previsão, nomeadamente o método naïve. Para séries temporais não sazonais o erro escalado para a série  $i$  e horizonte  $h$  é dado por:

$$q_{i,h} = \frac{y_{N+h} - \hat{y}_h}{\frac{1}{N-1} \sum_{t=2}^N |y_t - y_{t-1}|} \quad (4.3)$$

Se  $q_{i,h}$  for inferior a um então corresponde a uma previsão que é melhor do que a previsão média do método naïve, calculada no conjunto de treino. Inversamente, se  $q_{i,h}$  for superior a um então corresponde a uma previsão que é pior do que a previsão média do método naïve, calculada no conjunto de treino. Para séries temporais sazonais o erro escalado para a série  $i$  e horizonte  $h$  é dado por:

$$q_{i,h} = \frac{y_{N+h} - \hat{y}_h}{\frac{1}{N-m} \sum_{t=m+1}^N |y_t - y_{t-m}|} \quad (4.4)$$

onde  $m$  é o período da sazonalidade. O erro escalado absoluto médio (*Mean Absolute Scaled Error* - MASE) é obtido calculando a média do valor absoluto dos erros escalados  $|q_{i,h}|$  de todas as séries, relativos a cada horizonte  $h$ . O MASE, tal como o sMAE, é também apropriado para avaliar o desempenho dos modelos e métodos em termos de magnitude do enviesamento das estimativas.

Segundo Petropoulos e Kourentzes (2015), quer o MSE quer o MAE podem em certas circunstâncias focar-se em períodos de procura nula favorecendo previsões distorcidas. Esta situação é particularmente relevante para séries com um elevado grau de intermitência. Tentando ultrapassar estas limitações, Petropoulos e Kourentzes (2015) utilizam a medida de enviesamento Períodos em *Stock* (*Periods In Stock* - PIS). Esta métrica mede o número de períodos que uma unidade de um SKU esteve em *stock* ou o número de períodos de rutura de *stock*. Para a série  $i$  e horizonte  $h$  o PIS é dado por:

$$PIS_i = \sum_{h=1}^H \sum_{j=1}^h (\hat{y}_j - y_{N+j}) \quad (4.5)$$

onde  $H$  é a duração do horizonte de previsão. Valores positivos de PIS significam acumulação de *stock* enquanto que valores negativos significam rutura de *stock*.

Para entender melhor o cálculo desta métrica apresenta-se na Tabela 2 um exemplo ilustrativo desse cálculo para uma série temporal com 10 observações.



Período	Procura	Previsão	Erro	Stock atualizado	Soma acumulada
1	0	2	2	2	2
2	0	1	1	3	5
3	3	5	2	5	10
4	5	6	1	6	16
5	1	0	-1	5	21
6	0	2	2	7	28
7	4	4	0	7	35
8	0	2	2	9	44
9	1	4	3	12	56
10	9	1	-8	4	60
				60	PIS

Tabela 2. Cálculo do valor do PIS

Nomeadamente para  $H = 4$  o valor do PIS é:

$$\text{PIS} = ((2-0)+(1-0)+(2-0)) + ((5-3)+(1-0)+(2-0)+(2-0)+(1-0)+(2-0)) + ((6-5)+(5-3)+(1-0)+(2-0)+(5-3)+(1-0)+(2-0)+(2-0)+(1-0)+(2-0)) = \mathbf{16}$$

Para tornar esta medida independente de escala pode novamente utilizar-se o valor médio do conjunto de treino da série. Assim, o PIS escalado (*scaled Periods In Stock* -  $sPIS$ ) para a série  $i$  e horizonte  $h$  é dado por:

$$sPIS_i = \frac{PIS_i}{\frac{1}{N} \sum_{t=1}^N y_t} \quad (4.6)$$

O valor absoluto do  $sPIS$  é também considerado uma medida da magnitude do enviesamento das estimativas. Para a série  $i$  e horizonte  $h$ , o PIS absoluto escalado (*scaled Absolute Periods In Stock* -  $sAPIS$ ) é dado por:

$$sAPIS_i = \frac{|PIS_i|}{\frac{1}{N} \sum_{t=1}^N y_t} \quad (4.7)$$

O PIS absoluto escalado médio (*scaled Mean Absolute Periods In Stock* -  $sMAPIS$ ) é obtido calculando a média do PIS absoluto escalado de todas as séries, relativos a cada horizonte  $h$ . Uma vez que o período de dados históricos não é grande, para aumentar a fiabilidade das

medidas de erro (aumentando o número de erros disponíveis) foi implementado um processo de previsão com *rolling forecasting origin*. Este processo de previsão consiste na sucessiva atualização da origem de previsão (instante de tempo a partir do qual a previsão é efetuada), aumentando-se gradualmente o conjunto de treino e mantendo-se o horizonte temporal de previsão constante.

Este procedimento consiste nas seguintes etapas (Hyndman e Athanasopoulos, 2018) para  $h = 1$ :

- Estimar o modelo de previsão utilizando as observações até ao instante  $1, 2, \dots, k + i - 1$  e calcular a previsão para o instante  $k + i$  e respetivo erro.
- Repetir a etapa anterior para  $i = 1, 2, \dots, T - k$ , sendo  $T$  o número total de observações da série.
- Avaliar a precisão da previsão com base nas medidas de erro consideradas.

Como mostra a Figura 2, neste trabalho foi considerado para cada série um conjunto de treino inicial com 139 observações, sendo que a última observação é a origem da previsão. Este conjunto de treino é utilizado para estimar os parâmetros do modelo/método que é usado de seguida para obter previsões para os próximos quatro instantes (140–143), ou seja, foi definido um horizonte de previsão de quatro períodos ( $h = 4$ ), o que permite analisar o desempenho das várias abordagens para mais do que um passo de previsão. Seguidamente, o conjunto de treino é aumentado em um instante, passando a origem de previsão a ser 140. Os parâmetros do modelo/método são novamente re-estimados, e de seguida são obtidas as previsões para os quatro instantes seguintes (141 a 144). Este processo continua sucessivamente, período após período, até se atingir a última origem - 169, a partir da qual se obtêm as últimas previsões para os instantes 170-173. Terminado o processo são obtidas 34 previsões em cada horizonte. Estas previsões foram depois utilizadas para calcular as medidas de erro sMAE, sMSE, MASE e sMAPIS para cada horizonte  $h$ .

	1	2	3	...	139	140	141	142	143	144	145	146	...	165	166	167	168	169	170	171	172	173
Origem=139																						
Origem=140																						
Origem=141																						
Origem=142																						
...																						
Origem=166																						
Origem=167																						
Origem=168																						
Origem=169																						

Figura 2. Processo de *rolling*

#### 4.4. Resultados

Nesta secção são analisados os resultados das previsões obtidos com os catorze modelos/métodos descritos no Capítulo 3. Estes mostram os vários resultados tanto com como sem a inclusão das variáveis exógenas, sendo possível a comparação das diferentes abordagens, assim como perceber como as promoções afetam as previsões de vendas. Como se pode observar, a avaliação do desempenho de previsão destes modelos/métodos foi determinada utilizando quatro medidas de erro: o sMAE, o sMSE, o MASE e o sMAPIS.

No Anexo 5 apresentam-se os resultados globais para cada um dos modelos de previsão avaliados por estas quatro medidas. De forma a analisar a eficácia dos modelos em períodos promocionais, no Anexo 5, encontra-se simultaneamente os resultados referentes a modelos com a inclusão dos regressores (promoções) e os resultados dos modelos que não incluem regressores. Os modelos que incluem os regressores são definidos como iETSX(MYN) e encontram-se sublinhados a azul. Estes modelos apresentam erro multiplicativo (M) e tendência (Y) que pode ser nenhuma (N), multiplicativa (M) ou multiplicativa amortecida ( $M_d$ ), não havendo sazonalidade (N). A seleção do melhor destes três modelos possíveis é feita através do AIC. Todos os restantes modelos não incluem regressores. Para além disso, encontra-se na última coluna dos resultados uma ordenação média - *rank* médio (*avgrank* – *average rank*) que permite seriar os mesmos. O *rank* médio foi determinado através da ordenação média de todos os horizontes temporais. Primeiro realiza-se uma ordenação do melhor para o pior modelo em cada coluna, ou seja, associado a cada valor colocamos a sua ordem na coluna (de 1 a 14); depois disto, para cada linha/modelo existem quatro valores de ordenação (um para cada horizonte temporal), sendo com estes realizada uma média por linha para a obtenção do *rank* médio. Analisando o Anexo 5 podemos concluir que para as quatro medidas de erro, em todos os horizontes temporais, o modelo que apresenta o melhor desempenho, ou seja, o menor valor de cada medida é o iETSX(MYN)<sub>p</sub>, modelo de espaço de estados com probabilidade de ocorrência de procura baseada no TSB, com regressores. Este facto pode estar associado com a sua forma de atualização, ou seja, a probabilidade é continuamente estimada ao longo de vários períodos e, para além disso, inclui também a informação adicional dos regressores. Em relação ao modelo iETS(MYN)<sub>a</sub>/iETSX(MYN)<sub>a</sub> seria de esperar uma melhor performance, apesar de, de um modo geral, estar numa posição superior à do iETS(MYN)<sub>f</sub>/iETSX(MYN)<sub>f</sub>, que apresenta piores resultados do que o iETS(MYN)<sub>i</sub>/iETSX(MYN)<sub>i</sub>.

Em relação aos modelos com pior performance, também para as quatro medidas de erro e horizontes o pior modelo é o *naïve*, o método mais simples. Sendo isto já expectável devido à simplicidade do método, o mesmo não acontece com o facto do método de Croston apresentar melhor performance do que o SBA. Para além disso, é evidente na maioria dos casos que geralmente surgem com melhores resultados os modelos de espaço de estados com e sem regressores, de seguida o iMAPA e por fim os modelos para dados intermitente, terminando a lista com o *naïve*. A posição do iMAPA nos resultados vai ao encontro do que era esperado, mostrando-se que a agregação temporal e a combinação de previsões pode ser eficaz. Uma outra forma, mais visual, de representar os resultados obtidos, ou seja, o *rank* dos modelos para os horizontes temporais é através da representação gráfica exibida no Anexo 6.

Para determinar se os resultados dos modelos obtidos são estatisticamente diferentes foi realizado o teste Nemenyi calculado com os valores dos erros em cada passo do *rolling* e, representados nos Anexos 7-10, onde o eixo dos *yy* representa o *rank* médio para cada modelo e as linhas verticais mostram o conjunto de modelos no qual a diferença entre os *rank*s é estatisticamente insignificante. No caso de uma diferença ser tão pequena que estatisticamente não é significativa, não é possível afirmar categoricamente que uns modelos são melhores que outros, porque na realidade estatisticamente são semelhantes, no entanto, analisando os Anexo 7-10 é incontestável que a ordenação está associada a uma distinção que estatisticamente é evidente.

Apresentado na Tabela 3, foi calculado o ganho obtido pelos modelos para cada medida de erro, utilizando o método *naïve* como comparação. Este foi o método escolhido pois, para dados de natureza intermitente, está assente na literatura como um bom *benchmark*. Os modelos que proporcionam maiores ganhos encontram-se assinalados a negrito. Para além disso, na Tabela 3 encontram-se entre parêntesis os ganhos dos modelos com regressores relativamente aos modelos correspondentes sem regressores. Os ganhos apresentam valores negativos, uma vez que os valores dos erros dos modelos são inferiores aos valores dos erros do *naïve*, sendo estes calculados da seguinte forma:

$$Ganho = \frac{Erro\ do\ modelo - Erro\ do\ naïve}{Erro\ do\ naïve} \quad (4.8)$$

A obtenção dos ganhos entre parênteses segue o mesmo raciocínio. O método que apresenta maiores ganhos face ao método mais simples, é o iETX(MYN)p, ganhos que variam entre

17% e 27%, ou seja, este modelo melhora aproximadamente a previsão naïve entre 17% e 27%. Em 75% dos erros, o modelo que apresenta menores ganhos é o SBA, e ainda assim, consegue melhorias entre 8% a 16%. Estes valores demonstram que a escolha do modelo a utilizar é bastante importante, pois permite ganhos percentuais significativos, principalmente, no setor do retalho, com grandes volumes de negócio. Para além da análise das diferenças entre os vários modelos, no geral, foi também feita uma análise dos ganhos obtidos com a inclusão das promoções. Ou seja, foi efetuada uma comparação dos ganhos obtidos entre o modelo que incorpora as promoções e o modelo correspondente sem incorporação de promoções. Analisando os valores entre parêntesis da Tabela 3, conclui-se que todos os modelos que incluem as promoções apresentam melhores resultados que os modelos que não incluem, o que corrobora a teoria de que a informação promocional pode melhorar a previsão. Num setor com elevada concorrência de preços e com constantes alterações estratégicas, as decisões tomadas com base nos resultados/ganhos obtidos permitem ao retalhista, no global, uma redução das despesas. Ou seja, com a implementação do melhor método de previsão com a inclusão de promoções, indispensáveis nos dias de hoje no setor, o retalhista como consequência direta diminuirá significativamente as suas perdas e obterá lucros superiores. Para além disso, como consequência indireta da realização das previsões, terá uma gestão de *stocks* mais eficiente e próxima da realidade aumentando assim a satisfação dos clientes e com isso o sucesso do negócio.

sMAE	t+1	t+2	t+3	t+4	AvgRank	sMSE	t+1	t+2	t+3	t+4	AvgRank
iETSX(MYN)p	<b>-25,3%</b> (-1,2%)	<b>-26,8%</b> (-2,2%)	<b>-26,3%</b> (-2,3%)	<b>-24,6%</b> (-2,7%)	1,0	iETSX(MYN)p	<b>-16,7%</b> (-0,3%)	<b>-17,3%</b> (-0,8%)	<b>-16,6%</b> (-1,3%)	<b>-13,9%</b> (-3,9%)	1,0
iETS(MYN)p	-24,4%	-25,2%	-24,6%	-22,5%	2,0	ETS(ANN)	-15,9%	-16,4%	-16,0%	-13,5%	3,5
iETSX(MYN)i	-22,7%(-1,3%)	<b>-24,6%</b> (-2,2%)	<b>-24,1%</b> (-2,3%)	<b>-22,5%</b> (-2,7%)	3,0	iETSX(MYN)i	-16,2%(-0,1%)	-16,9%(-0,9%)	-15,4%(-1,3%)	<b>-11,9%</b> (-3,9%)	3,5
iETS(MYN)i	-21,7%	-22,8%	-22,3%	-20,3%	4,3	iETS(MYN)p	-16,5%	-16,7%	-15,5%	-10,3%	4,0
iETSX(MYN)a	-19,9%(-1,0%)	-22,0%(-1,6%)	-22,0%(-1,6%)	-20,6%(-1,8%)	4,8	iETSX(MYN)a	<b>-15,7%</b> (-2,1%)	<b>-16,4%</b> (-2,3%)	<b>-15,7%</b> (-2,4%)	-12,8%(-3,0%)	4,0
iETS(MYN)a	-19,1%	-20,8%	-20,7%	-19,1%	6,0	iMAPA	-13,9%	-14,6%	-14,2%	-11,4%	6,8
iETSX(MYN)f	-17,9% <b>(-1,5%)</b>	-19,9%(-1,8%)	-20,0%(-1,9%)	-18,6%(-1,9%)	7,0	iETS(MYN)i	-16,1%	-16,2%	-14,3%	-8,3%	7,3
iETS(MYN)f	-16,6%	-18,4%	-18,5%	-17,0%	8,0	iETSX(MYN)f	-13,3%(-1,8%)	-14,0%(-1,8%)	-13,5%(-1,8%)	-10,7%(-2,0%)	8,3
iMAPA	-15,8%	-17,8%	-18,1%	-16,9%	9,3	iETS(MYN)a	-13,9%	-14,4%	-13,7%	-10,1%	8,5
ETS(ANN)	-16,4%	-17,3%	-17,0%	-15,3%	10,0	TSB	-12,7%	-13,4%	-13,1%	-10,3%	9,5
TSB	-14,4%	-16,4%	-16,7%	-15,5%	10,8	Croston	-12,6%	-13,3%	-13,0%	-10,2%	10,5
Croston	-13,9%	-16,0%	-16,4%	-15,2%	12,0	SBA	-12,6%	-13,3%	-13,0%	-10,2%	11,5
SBA	-13,9%	-16,0%	-16,3%	-15,1%	13,0	iETS(MYN)f	-11,7%	-12,4%	-11,9%	-8,9%	12,8
Naïve	<i>1,534</i>	<i>1,570</i>	<i>1,575</i>	<i>1,558</i>	14,0	Naïve	<i>38,813</i>	<i>39,304</i>	<i>39,587</i>	<i>40,342</i>	14,0
MASE	t+1	t+2	t+3	t+4	AvgRank	sMAPIS	t+1	t+2	t+3	t+4	AvgRank
iETSX(MYN)p	<b>-23,5%</b> (-1,4%)	<b>-25,0%</b> (-2,6%)	<b>-24,6%</b> (-2,7%)	<b>-23,2%</b> (-3,1%)	1,0	iETSX(MYN)p	<b>-25,3%</b> (-1,2%)	<b>-25,8%</b> (-1,5%)	<b>-26,0%</b> (-1,7%)	<b>-25,9%</b> (-1,9%)	1,0
iETSX(MYN)i	-21,1% <b>(-1,5%)</b>	<b>-23,2%</b> (-2,7%)	<b>-22,9%</b> (-2,8%)	<b>-21,6%</b> (-3,1%)	2,3	iETS(MYN)p	-24,4%	-24,7%	-24,7%	-24,5%	2,0
iETS(MYN)p	-22,4%	-23,0%	-22,5%	-20,8%	2,8	iETSX(MYN)i	-22,7%(-1,3%)	-23,3% <b>(-1,6%)</b>	<b>-23,5%</b> (-1,8%)	<b>-23,5%</b> (-1,9%)	3,0
iETS(MYN)i	-19,9%	-21,1%	-20,7%	-19,1%	4,0	iETS(MYN)i	-21,7%	-22,1%	-22,2%	-22,0%	4,0
iETSX(MYN)a	-14,9%(-1,1%)	-17,4%(-1,7%)	-17,8%(-1,7%)	-16,9%(-1,9%)	5,3	iETSX(MYN)a	-19,9%(-1,0%)	-20,6%(-1,2%)	-21,0%(-1,3%)	-21,1%(-1,4%)	5,0
ETS(ANN)	-16,5%	-17,3%	-17,0%	-15,8%	5,8	iETS(MYN)a	-19,1%	-19,7%	-19,9%	-19,9%	6,0
iETS(MYN)a	-14,0%	-16,0%	-16,3%	-15,3%	7,0	iETSX(MYN)f	<b>-17,9%</b> (-1,5%)	<b>-18,6%</b> (-1,6%)	-18,9%(-1,6%)	-19,0%(-1,7%)	7,0
iETSX(MYN)f	-12,5% <b>(-1,5%)</b>	-14,8%(-1,8%)	-15,3%(-1,9%)	-14,5%(-2,0%)	8,0	iETS(MYN)f	-16,6%	-17,2%	-17,6%	-17,6%	8,0
iMAPA	-11,2%	-13,6%	-14,4%	-13,9%	9,0	iMAPA	-15,8%	-16,5%	-16,9%	-17,0%	9,5
iETS(MYN)f	-11,2%	-13,2%	-13,7%	-12,8%	10,0	ETS(ANN)	-16,4%	-16,7%	-16,8%	-16,7%	9,5
TSB	-8,8%	-11,3%	-12,1%	-11,7%	11,0	TSB	-14,4%	-15,1%	-15,5%	-15,6%	11,0
Croston	-8,0%	-10,6%	-11,4%	-11,0%	12,0	Croston	-13,9%	-14,6%	-15,1%	-15,2%	12,0
SBA	-7,8%	-10,4%	-11,3%	-10,9%	13,0	SBA	-13,9%	-14,6%	-15,0%	-15,1%	13,0
Naïve	<i>1,795</i>	<i>1,844</i>	<i>1,860</i>	<i>1,861</i>	14,0	Naïve	<i>1,534</i>	<i>4,637</i>	<i>9,315</i>	<i>15,551</i>	14,0

Tabela 3. Ganho dos métodos em relação ao Naïve. Entre parêntesis, ganho dos modelos com X relativamente aos modelos equivalentes sem X

## 5. Conclusões

A obtenção de previsões de vendas próximas do valor real da procura é cada vez mais importante para que os retalhistas tenham um negócio estável e de sucesso. No entanto, a obtenção dessas previsões representa um problema no setor do retalho, onde as ações promocionais são contantes e os produtos têm procura intermitente.

Neste contexto, o objetivo desta dissertação era melhorar as previsões de vendas de produtos de natureza intermitente, incorporando variáveis promocionais, para que, as previsões estejam mais próximas da realidade, num ambiente complexo e competitivo como o atual. Isto permite ao retalhista tomar decisões mais concretas em relação aos produtos a promover, praticando uma gestão de *stocks* eficiente.

O trabalho foi realizado utilizando um conjunto de dados históricos de vendas diárias de lojas Pingo Doce, de Janeiro de 2012 a Abril de 2015, fornecidos pelo Grupo Jerónimo Martins. Em particular, foi escolhida para o estudo uma loja de grande dimensão. Os dados fornecidos sofreram tratamento, como a agregação semanal das vendas, a seleção dos dados de natureza intermitente e a identificação das promoções.

Foram estimados catorze modelos de previsão de vendas, sendo estes divididos em duas categorias, modelos que incluem regressores e modelos que não incluem. Esta separação foi feita com o intuito de perceber se a informação promocional melhora a precisão das previsões de vendas.

As previsões foram obtidas para um período de quatro semanas, tendo sido utilizado um processo de *rolling* nas previsões para aumentar a fiabilidade das medidas de erro, devido ao tamanho relativamente reduzido do período de dados históricos, que faz sentido neste caso (devido à elevada dinâmica do setor).

De forma a avaliar o desempenho dos modelos foram utilizadas as medidas de erro sMAE, sMSE, MASE e sMAPIS adequadas para séries intermitentes, que permitiram avaliar o desempenho dos diferentes modelos em períodos com e sem promoção. Esta dissertação utilizou duas vertentes metodológicas: os métodos clássicos para dados intermitentes e os modelos mais recentes para esse tipo de séries, os modelos de espaço de estados. A sua utilização foi motivada para abranger a diversidade de técnicas existentes na literatura para a previsão de vendas deste tipo de dados.

Com base nos resultados obtidos, pode afirmar-se que segundo as medidas de erro utilizadas, no geral, os modelos de espaço de estados são os mais eficazes. O modelo que

apresenta o melhor desempenho é o iETSX(MYN)<sub>p</sub>, ou seja, o modelo de espaço de estados com probabilidade de ocorrência de procura baseada no TSB, com a inclusão de regressores. Em relação aos modelos com pior performance, também para as quatro medidas de erro, o pior modelo é o naïve, o modelo mais simples. Foram realizados testes estatísticos que mostram que os resultados dos modelos são estatisticamente diferentes e significativos. Para além disso, os resultados confirmam a teoria de que a informação promocional melhora a previsão, pois os modelos com regressores apresentaram melhores resultados em comparação com os mesmos modelos sem regressores, para todos os erros.

Este estudo pode ser estendido sob várias perspetivas. O facto de ter sido aplicado com sucesso a uma loja sugere que possa ser replicado a outras lojas, com diferentes características, de modo a poder confirmar-se as conclusões obtidas. Para além disso, o uso de regressores limitou-se à inclusão de promoções. No entanto, durante o estudo concluiu-se que existem outros fatores que podem influenciar o negócio dos retalhistas. Entre estes destacam-se o preço, o desconto relativo, os eventos de calendário, a última semana de cada mês, devido ao impacto que provocam no consumo, uma vez que se considera que as vendas são maiores nos feriados e em momentos festivos (e por vezes também nas semanas anteriores e seguintes) e é normalmente no final de cada mês que os salários são recebidos, aumentando o capital disponível dos clientes para o consumo. No entanto, a aplicação de modelos com um elevado número de regressores traz dificuldades. Para além do processamento elevado e do problema da multicolinearidade existe também a possibilidade de *overfitting*, sendo habitualmente necessário recorrer a técnicas como *Principal Components Analysis*. Contudo, em investigações futuras seria interessante explorar a inclusão dos regressores mencionados, pois o erro de previsão poderá potencialmente diminuir, tendo em conta o sucesso obtido neste caso de estudo.

Por fim, pode afirmar-se que este trabalho é um contributo importante e um avanço significativo na área da previsão de dados intermitentes, que ainda se encontra numa fase inicial. O trabalho permitiu perceber quais os melhores modelos a utilizar nas previsões de dados de natureza intermitente, quais os fatores externos a incluir e a importância dos mesmos para os retalhistas. É um trabalho inovador e poderá ter um impacto económico importante nas empresas, uma vez que a realidade atual dos sistemas de previsão utilizados por estas está ainda muito atrás dos modelos defendidos neste trabalho.



## 6. Referências Bibliográficas

- Aburto, L. e Weber, R. (2007), “Improved Supply Chain Management Based on Hybrid Demand Forecasts”, *Applied Soft Computing*, Vol. 7, N°1, pp. 136–144.
- Aras, S., Deveci Kocakoç, İ. e Polat, C. (2017), “Comparative study on retail sales forecasting between single and combination methods”, *Journal of Business Economics and Management*, Vol. 18, N°5, pp. 803-832.
- Bawa, K. e Shoemaker, R. W. (1987), “The Effects of a Direct Mail Coupon on Brand Choice Behavior”, *Journal of Marketing Research*, Vol. 24, N°4, pp. 370–376.
- Bell, D. R., Chiang, J. e Padmanabhan, V. (1999), “The Decomposition of Promotional Response: An Empirical Generalization”, *Marketing Science*, Vol. 18, N°4, pp. 504–526.
- Blattberg, R. e Neslin, S. (1990), *Sale promotion: concepts, methods and strategies*, 1ª edição, Englewood Cliffs, N.J.: Prentice Hall.
- Bolton, R., Shankar, V. e Montoya, D. (2010), “Recent Trends and Emerging Practices in Retail Pricing”, em Karft, M. e Mantrala, M. (editores), *Retailing in the 21st century. Current and Future Trends*, 1ª edição, Alemanha, Springer-Verlag, pp. 255-269.
- Brown, R.G. (1959), *Statistical forecasting for inventory control*, New York: McGraw-Hill.
- Caiado, J. (2016), *Métodos de Previsão em Gestão*, 2ª edição, Edições Sílabo.
- Chaharsoughi, S. e Yasory, T. (2012), “Effect of sales promotion on consumer behavior based on culture”, *African Journal of Business Management*, Vol. 6, N°1, pp. 98–102.
- Chapados, N., Joliveau, M., L’Ecuyer, P. e Rousseau, L. M. (2014), “Retail store scheduling for profit”, *European Journal of Operational Research*, Vol. 239(3), pp. 609–624.
- Cooper, L., Baron, P., Wayne, L., Swisher, M. e Gogos, P. (1999), “PromoCast: A New Forecasting Method for Promotion Planning”, *Marketing Science*, Vol. 18, N°3, pp. 301–316.
- Corsten, D. e Gruen, T. (2003), “Desperately seeking shelf availability: an examination of the extent, the causes, and the efforts to address retail out-of-stocks”, *International Journal of Retail & Distribution Management*, Vol. 31, N°12, pp. 605–617.
- Corsten, D. e Gruen, T. (2004), “Stock-Outs Cause Walkouts”, <https://hbr.org/2004/05/stock-outs-cause-walkouts>, acessado a 3 de Janeiro de 2018.
- Croston, J. D. (1972), “Forecasting and Stock Control for Intermittent Demands”, *Journal of the Operational Research Society*, Vol. 23, N°3, pp. 289–303.
- Curry, D. J., Divakar, S., Mathur, S. K. e Whiteman, C. H. (1995), “BVAR as a category management tool: An illustration and comparison with alternative techniques”, *Journal*

- of Forecasting*, Vol. 14, N°3, pp. 181–199.
- Dinheiro Vivo (2017), “Promoções não param de crescer. Já são 44,8% das vendas no alimentar”, <https://www.dinheirovivo.pt/empresas/promocoes-nao-para-de-crescer-ja-sao-448-das-vendas-no-alimentar/>, acedido a 3 de Janeiro de 2018.
- Dinheiro Vivo (2018a), “Dono do Pingo Doce com lucros de 385 milhões o ano passado”, <https://www.dinheirovivo.pt/empresas/dono-do-pingo-doce-com-lucros-de-385-milhoes-o-ano-passado/>, acedido a 1 de Março de 2018.
- Dinheiro Vivo (2018b), “Dono do Pingo Doce vai investir 130 milhões em Portugal e abrir 10 lojas”, <https://www.dinheirovivo.pt/empresas/dono-do-pingo-doce-vai-investir-130-milhoes-em-portugal/>, acedido a 1 de Março de 2018.
- Dinheiro Vivo (2018c), “Promoções não param de crescer. Já são 45% das vendas em Portugal”, <https://www.dinheirovivo.pt/empresas/promocoes-ja-sao-45-das-vendas-em-portugal/>, acedido a 22 de Maio de 2018.
- ECR Europe (2003), *ECR - Optimal Shelf Availability: Increasing Shopper Satisfaction at the Moment of Truth*, ECR Europe, Brussels.
- Fildes, R., Goodwin, P., Lawrence, M. e Nikolopoulos, K. (2009), “Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning”, *International Journal of Forecasting*, Vol. 25, N°1, pp. 3–23.
- Gardener, E. e Trivedi, M. (1998), “A Communications Framework to Evaluate Sales Promotion Strategies”, *Journal of Advertising Research*, Vol. 38, pp. 67–71.
- Guadagni, P. e Little, J. D. (1983), “A logit model of brand choice calibrated on scanner data”, *Marketing Science*, Vol. 2, pp. 203–238.
- Gupta, S. (1988), “Impact of Sales Promotions on When, What, and How Much to Buy”, *Journal of Marketing Research*, Vol. 25, N°4, pp. 342–355.
- Heerde, H., Gupta, S. e Wittink, D. (2003), “Is 3/4 of the Sales Promotion Bump Due to Brand Switching? No, it is 1/3”, *Journal of Marketing Research*, Vol. 5, pp. 1–30.
- Hinton, J. (1999), *Defence inventory, continuing challenges in managing inventories and avoiding adverse operational effects*, Washington, D.C., US General Accounting Office.
- Honea, H. e Dahl, D. (2005), “The promotion affect scale: Defining the affective dimensions of promotion”, *Journal of Business Research*, Vol. 58, N°4, pp. 543–551.
- Huang, T., Fildes, R. e Soopramanien, D. (2014), “The value of competitive information in forecasting FMCG retail product sales and the variable selection problem”, *European Journal of Operational Research*, Vol. 237, N°2, pp. 738–748.

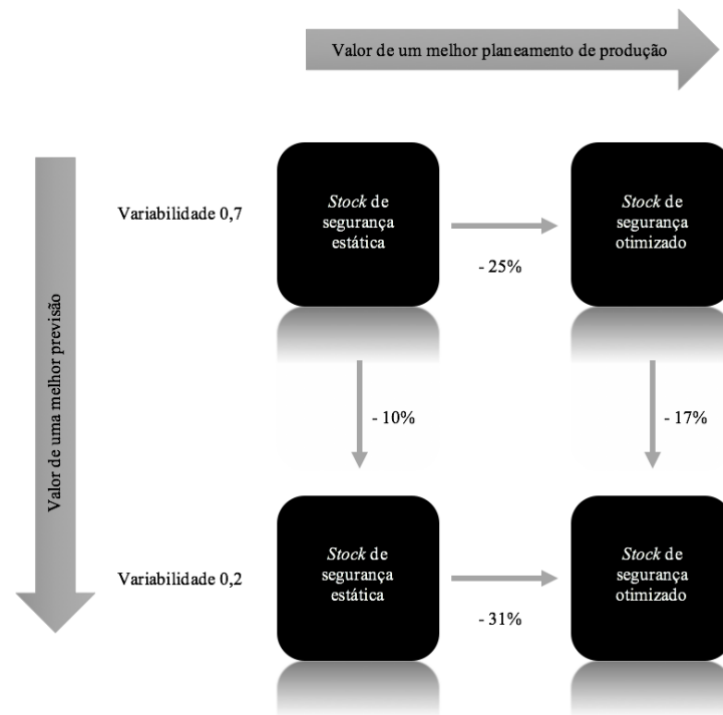
- Hyndman, R. J. e Athanasopoulos, G. (2018), *Forecasting: principles and practice* (2ª Edição), Otexts.com.
- Hyndman, R. J. e Athanasopoulos, G. (2012), *Forecasting: principles and practice* (1ª Edição), Otexts.com.
- Hyndman, R. J. e Koehler, A. B. (2006), “Another look at measures of forecast accuracy”, *International Journal of Forecasting*, Vol. 22, pp. 679–688.
- Hyndman, R. J., Koehler, A. B., Ord, J. K., e Snyder, R. D. (2008), *Forecasting with Exponential Smoothing*, Springer Series in Statistics.
- IBM ILOG (2010), “Supply Chain News: Looking to Reduce Inventories? Production Scheduling Optimization May Have Bigger Impact than Improving Forecast Accuracy”, [http://www.scdigest.com/assets/On\\_Target/10-11-02-1.php?cid=3869](http://www.scdigest.com/assets/On_Target/10-11-02-1.php?cid=3869), acessado a 20 de Janeiro de 2018.
- Jerónimo Martins (2016), “Our History”, <https://www.youtube.com/channel/UCvNmrfc3d5IBPVQs-6Ij2Rw>, acessado a 20 de Fevereiro de 2018.
- Jerónimo Martins (2018a), “O que fazemos”, <https://www.jeronimomartins.com/pt/sobre-nos/o-que-fazemos/>, acessado a 23 de Fevereiro de 2018.
- Jerónimo Martins (2018b), “Onde Estamos”, <https://www.jeronimomartins.com/pt/sobre-nos/onde-estamos/>, acessado a 23 de Fevereiro de 2018.
- Jerónimo Martins (2018c), “Pingo Doce”, <https://www.jeronimomartins.com/pt/sobre-nos/o-que-fazemos/distribuicao-alimentar/pingo-doce/>, acessado a 15 de Abril de 2018.
- Jerónimo Martins (2018d), *Relatório de Contas Provisório 2017*, Portugal.
- Johnston, F., Boylan, J. e Shale, E. (2003), “An examination of the size of orders from customers, their characterisation and the implications for inventory control of slow moving items”, *Journal of the Operational Research Society*, Vol. 54, N°8, pp. 833–837.
- Kia Motors Corporation (2016), *Annual Report 2016 - Jerónimo Martins*, Portugal.
- Kolassa, S. (2016), “Evaluating predictive count data distributions in retail sales forecasting”, *International Journal of Forecasting*, Vol. 32, N°3, pp. 788–803.
- Kotler, P. e Keller, K. L. (2012), *Marketing Management*, 14ª edição, New Jersey: Prentice Hall.
- Kourentzes, N. (2013), “Intermittent demand forecasts with neural networks”, *International Journal of Production Economics*, Vol. 143, N°1, pp. 198–206.
- Kourentzes, N. (2014), “On intermittent demand model optimisation and selection”,

- International Journal of Production Economics*, Vol. 156, pp. 180–190.
- Kourentzes, N. e Petropoulos, F. (2016), “Forecasting with multivariate temporal aggregation: The case of promotional modelling”, *International Journal of Production Economics*, Vol. 181, pp. 145–153.
- Kourentzes, N., Petropoulos, F. e Trapero, J. R. (2014), “Improving forecasting by estimating time series structural components across multiple frequencies”, *International Journal of Forecasting*, Vol. 30, N° 2, pp. 291–302.
- Ma, S. e Fildes, R. (2017), “A retail store SKU promotions optimization model for category multi-period profit maximization”, *European Journal of Operational Research*, Vol. 260, N°2, pp. 680–692.
- Marktest, G. (2014), “Boom Promocional na grande distribuição”, <http://www.marktest.com/wap/a/n/id~1d6f.aspx>, acessado a 9 de Dezembro de 2017.
- Mentzer, J. T. e Moon, M. A. (2004), *Sales forecasting management: A demand management approach*, 2ª edição, Thousand Oaks, CA: SAGE.
- Mishra, A. e Mishra, H. (2011), “The Influence of Price Discount Versus Bonus Pack on the Preference for Virtue and Vice Foods”, *Journal of Marketing Research*, Vol. 48, N°1, pp. 196–206.
- Molenaers, A., Baets, H., Pintelon, L. e Waeyenberg, G. (2010), “Criticality classification of spare parts: A case study”, em *Preprints of the 16th International Working Seminar on Production Economics*.
- Moon, M., Mentzer, J. e Smith, C. (2003), “Conducting a sales forecasting audit”, *International Journal of Forecasting*, Vol. 19, pp. 5–25.
- Nikolopoulos, K., Syntetos, A. A., Boylan, J. E., Petropoulos, F. e Assimakopoulos, V. (2011), “An aggregate–disaggregate intermittent demand approach (ADIDA) to forecasting: an empirical proposition and analysis”, *Journal of the Operational Research Society*, Vol. 62, N°3, pp. 544–554.
- Petropoulos, F. e Kourentzes, N. (2015), “Forecast combinations for intermittent demand”, *Journal of the Operational Research Society*, Vol. 66, N°6, pp. 914–924.
- Petropoulos, F., Kourentzes, N. e Nikolopoulos, K. (2016), “Another look at estimators for intermittent demand”, *International Journal of Production Economics*, Vol. 181, pp. 154–161.
- Pickton, D. e Broderick, A. (2005), *Integrated Marketing Communications*, 2ª edição, England: Pearson Education Limited.
- Rao, A. (1973), “A comment on: Forecasting and stock control for intermittent demands”,

- Operational Research Quarterly*, Vol. 24, pp. 639–640.
- REN e Jerónimo Martins (2017), *Relatório e Contas 2017 - Jerónimo Martins*, Portugal.
- Rodrigues, C. (2015), “Promoções: que impacto nas vendas?”, *Revista Grande Consumo*, N°34: 30-34.
- Rothschild, M. e Gaidis, W. (1981), “Behavioral Learning Theory: Its Relevance to Marketing and Promotions”, *Journal of Marketing*, Vol. 45, pp. 70.
- Shale, E., Boylan, J. E. e Johnston, F. (2006), “Forecasting for intermittent demand: the estimation of unbiased average”, *Journal of the Operational Research Society*, Vol. 57, N°5, pp. 588–592.
- Shenstone, L. e Hyndman, R. J. (2005), “Stochastic models underlying Croston’s method for intermittent demand forecasting”, *Journal of Forecasting*, Vol. 24, N°6, pp. 389–402.
- Shimp, T. A. e Andrews, J. (2013), *Advertising, Promotion, and Other Aspects of Integrated Marketing Communications*, 9ª edição, Cengage Learning.
- Snyder, R. D., Ord, J. K. e Beaumont, A. (2012), “Forecasting the intermittent demand for slow-moving inventories: A modelling approach”, *International Journal of Forecasting*, Vol. 28, N°2, pp. 485–496.
- Srinivasan, S., Pauwels, K., Hanssens, D. e Dekimpe, M. (2002), “Who benefits from price promotions?”, *Harvard Business Review*, Vol. 9, pp. 22–23.
- Srinivasan, S., Pauwels, K., Hanssens, D. M. e Dekimpe, M. G. (2004), “Do Promotions Benefit Manufacturers, Retailers, or Both?”, *Management Science*, Vol. 50, N°5, pp. 617–629.
- Svetunkov, I. (2017), “Statistical models underlying functions of ‘smooth’ package for R”, Working Paper of Department of Management Science, Lancaster University, UK, 2017:1, 1-52.
- Svetunkov, I. e Boylan, J. E. (2017), “Multiplicative State-Space Models for Intermittent Time Series”, Working Paper of Department of Management Science, Lancaster University, UK, 2017:4, 1-43.
- Syntetos, A. A., Babai, Z., Boylan, J. E., Kolassa, S. e Nikolopoulos, K. (2016), “Supply chain forecasting: Theory, practice, their gap and the future”, *European Journal of Operational Research*, Vol. 252, N°1, pp. 1–26.
- Syntetos, A. A. e Boylan, J. E. (2001), “On the bias of information estimates”, *International Journal of Production Economics*, Vol. 71, N°2, pp. 457–466.
- Syntetos, A. A. e Boylan, J. E. (2005), “The accuracy of intermittent demand estimates”,

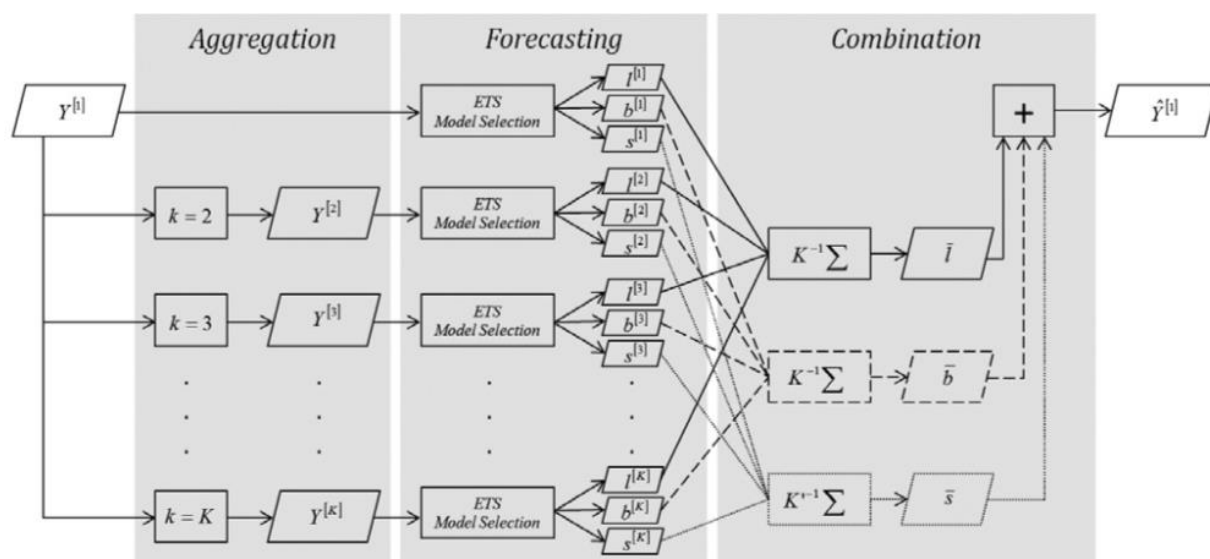
- International Journal of Forecasting*, Vol. 21, N°2, pp. 303–314.
- Syntetos, A. A. e Boylan, J. E. (2006), “On the stock control performance of intermittent demand estimators”, *International Journal of Production Economics*, Vol. 103, N°1, pp. 36–47.
- Syntetos, A. A., Keyes, M., e Babai, M. Z. (2009), “Demand categorisation in a European spare parts logistics network”, *International Journal of Operations & Production Management*, Vol. 29, N°3, pp. 292–316.
- Syntetos, A. A., Zied Babai, M. e Gardner, E. S. (2015), “Forecasting intermittent inventory demands: Simple parametric methods vs. bootstrapping”, *Journal of Business Research*, Vol. 68, N°8, pp. 1746–1752.
- Teunter, R., Syntetos, A. A. e Babai, M. Z. (2011), “Intermittent demand: Linking forecasting to inventory obsolescence”, *European Journal of Operational Research*, Vol. 214, N°3, pp. 606–615.
- Teunter, R. e Sani, B. (2009), “On the bias of Croston’s forecasting method”, *European Journal of Operational Research*, Vol. 194, N°1, pp. 177–183.
- Trapero, J. R., Pedregal, D. J., Fildes, R. e Kourentzes, N. (2013), “Analysis of judgmental adjustments in the presence of promotions”, *International Journal of Forecasting*, Vol. 29, N°2, pp. 234–243.
- Wallström, P. e Segerstedt, A. (2010), “Evaluation of forecasting error measurements and techniques for intermittent demand”, *International Journal of Production Economics*, Vol. 128, N°2, pp. 625–636.
- Willemain, T. R., Smart, C. N. e Schwarz, H. F. (2004), “A new approach to forecasting intermittent demand for service parts inventories”, *International Journal of Forecasting*, Vol. 20, N°3, pp. 375–387.
- Willemain, T. R., Smart, C. N., Shockor, J. H. e DeSautels, P. A. (1994), “Forecasting Demand in Manufacturing: a comparative evaluation of Croston’s method”, *International Journal Forecast*, Vol. 10, N°4, pp. 529–538.

## 7. Anexos



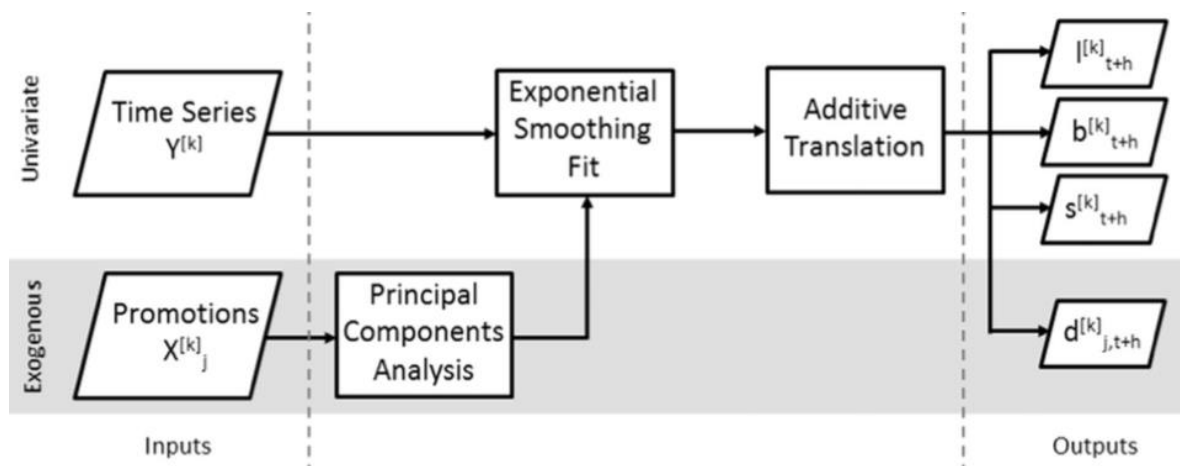
Fonte: IBM ILOG (2010)

Anexo 1. Impacto nos níveis de inventário com a melhoria da previsão versus programação da produção e otimização de stock de segurança



Fonte: Kourentzes *et al.* (2014)




## Anexo 2. Fases do método MAPA






Fonte: Kourentzes e Petropoulos (2016)

## Anexo 3. Fluxograma do processo do cálculo para cada nível de agregação temporal do MAPA com variáveis exógenas












Anexo 4. Séries de vendas, preços e promoções de seis SKUs

<b>sMAE</b>	t+1	t+2	t+3	t+4	AvgRank	<b>sMSE</b>	t+1	t+2	t+3	t+4	AvgRank
iETSX(MYN)p	1,145	1,150	1,160	1,175	1,0	iETSX(MYN)p	32,317	32,487	32,997	34,753	1,0
iETS(MYN)p	1,159	1,175	1,188	1,207	2,0	ETS(ANN)	32,631	32,861	33,257	34,895	3,5
iETSX(MYN)i	1,186	1,184	1,195	1,208	3,0	iETSX(MYN)i	32,520	32,664	33,494	35,547	3,5
iETS(MYN)i	1,201	1,212	1,223	1,242	4,3	iETS(MYN)p	32,416	32,733	33,447	36,178	4,0
iETSX(MYN)a	1,228	1,224	1,228	1,237	4,8	iETSX(MYN)a	32,709	32,854	33,363	35,162	4,0
iETS(MYN)a	1,241	1,244	1,248	1,260	6,0	iMAPA	33,418	33,570	33,950	35,728	6,8
iETSX(MYN)f	1,259	1,258	1,260	1,268	7,0	iETS(MYN)i	32,552	32,952	33,922	37,004	7,3
iETS(MYN)f	1,278	1,281	1,284	1,293	8,0	iETSX(MYN)f	33,636	33,820	34,228	36,027	8,3
iMAPA	1,291	1,290	1,289	1,295	9,3	iETS(MYN)a	33,416	33,629	34,173	36,262	8,5
ETS(ANN)	1,283	1,298	1,307	1,319	10,0	TSB	33,887	34,026	34,403	36,189	9,5
TSB	1,313	1,312	1,311	1,316	10,8	Croston	33,915	34,058	34,433	36,216	10,5
Croston	1,320	1,318	1,317	1,322	12,0	SBA	33,929	34,076	34,448	36,235	11,5
SBA	1,321	1,319	1,317	1,322	13,0	iETS(MYN)f	34,258	34,432	34,861	36,755	12,8
Naive	1,534	1,570	1,575	1,558	14,0	Naive	38,813	39,304	39,587	40,342	14,0
<b>MASE</b>	t+1	t+2	t+3	t+4	AvgRank	<b>sMAPIS</b>	t+1	t+2	t+3	t+4	AvgRank
iETSX(MYN)p	1,374	1,382	1,402	1,429	1,0	iETSX(MYN)p	1,145	3,440	6,895	11,524	1,0
iETSX(MYN)i	1,417	1,417	1,434	1,458	2,3	iETS(MYN)p	1,159	3,492	7,014	11,743	2,0
iETS(MYN)p	1,393	1,420	1,441	1,475	2,8	iETSX(MYN)i	1,186	3,557	7,122	11,894	3,0
iETS(MYN)i	1,438	1,456	1,474	1,505	4,0	iETS(MYN)i	1,201	3,614	7,250	12,128	4,0
iETSX(MYN)a	1,528	1,524	1,529	1,546	5,3	iETSX(MYN)a	1,228	3,680	7,360	12,277	5,0
ETS(ANN)	1,498	1,526	1,543	1,567	5,8	iETS(MYN)a	1,241	3,726	7,458	12,451	6,0
iETS(MYN)a	1,545	1,550	1,557	1,576	7,0	iETSX(MYN)f	1,259	3,777	7,554	12,599	7,0
iETSX(MYN)f	1,571	1,571	1,575	1,591	8,0	iETS(MYN)f	1,278	3,837	7,680	12,816	8,0
iMAPA	1,594	1,593	1,592	1,602	9,0	iMAPA	1,291	3,871	7,741	12,905	9,5
iETS(MYN)f	1,595	1,600	1,605	1,623	10,0	ETS(ANN)	1,283	3,864	7,752	12,958	9,5
TSB	1,638	1,636	1,634	1,644	11,0	TSB	1,313	3,939	7,875	13,127	11,0
Croston	1,652	1,649	1,647	1,657	12,0	Croston	1,320	3,958	7,913	13,189	12,0
SBA	1,654	1,652	1,649	1,659	13,0	SBA	1,321	3,960	7,917	13,197	13,0
Naive	1,795	1,844	1,860	1,861	14,0	Naive	1,534	4,637	9,315	15,551	14,0


Anexo 5. Resultados de erros de previsão sMAE, sMSE, MASE e sMAPIS




Anexo 6. Rank do desempenho dos modelos obtido com sMAE, sMSE, MASE e sMAPIS




Anexo 7. Teste estatístico Nemenyi para os quatro instantes com sAE



Anexo 8. Teste estatístico Nemenyi para os quatro instantes com sSE



Anexo 9. Teste estatístico Nemenyi para os quatro instantes com ASE



Anexo 10. Teste estatístico Nemenyi para os quatro instantes com sAPIS